


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ
ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF CONTROL AND INSTRUMENTATION

KOHONENOVA SÍŤ
KOHONEN NETWORK

BAKALÁŘSKÁ PRÁCE
BACHELOR'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. MILOSLAV FIC

VEDOUCÍ PRÁCE
SUPERVISOR

doc. Ing. VÁCLAV JIRSÍK, CSc.

BRNO 2012



VYSOKÉ UČENÍ
TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

Ústav automatizace a měřicí techniky

Bakalářská práce

bakalářský studijní obor
Automatizační a měřicí technika

Student: Bc. Miloslav Fic

ID: 120275

Ročník: 3

Akademický rok: 2011/2012

NÁZEV TÉMATU:

Kohonenova síť

POKYNY PRO VYPRACOVÁNÍ:

1. Seznamte se s problematikou samoorganizujících neuronových sítí se zaměřením na Kohonenovu síť.
2. Na zvolených tréninkových množinách zkoumejte vliv počátečního nastavení vah na konečnou "pozici" vítězných neuronů.
3. Na vybraných parametrech sítě zkoumejte jejich vliv na průběh učení Kohonenové sítě.
4. Dosažené výsledky zhodnoťte.

DOPORUČENÁ LITERATURA:

Šíma J., Neruda R.: Teoretické otázky neuronových sítí. Matfyzpress, Praha 1996

Termín zadání: 6.2.2012

Termín odevzdání: 28.5.2012

Vedoucí práce: doc. Ing. Václav Jirsík, CSc.

Konzultanti bakalářské práce:

doc. Ing. Václav Jirsík, CSc.
Předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

Abstrakt

Bakalářská práce se zabývá problematikou samoorganizujících neuronových sítí a jejich učícím mechanismem. Je rozebráno učení, aktivace a aplikace Kohonenovy sítě. Část bakalářské práce je věnována programu Kohonenovy neuronové sítě. Praktická část práce obsahuje citlivostní analýzu výsledného stavu sítě na učicí parametry a jejich vliv na průběh učení. Na zvolených variacích parametrů učení je zkoumán vliv počátečního nastavení vah na výslednou „pozici“ vítězných neuronů.

Klíčová slova

Samoorganizující neuronová síť, Kohonenova síť, SOM, parametry učení, počáteční nastavení vah.

Abstract

This Bachelor thesis deals with self-organizing networks and its learning mechanism. The activation, adaptation and application of Kohonen network are discussed in this thesis. The program Kohonen neural network is described. The practical part of this work analyzes effect of learning parameters choice on final state of Kohonen network and how do this learning parameters affect learning process. The effect of weight vector initialization on the final best-matching neuron “position” is analyzed.

Keywords

Self-Organizing network, Kohonen network, Kohonen Self-Organizing maps, learning parameters, weight vector initialization.

Bibliografická citace:

FIC, M.: *Kohonenova síť*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2012. 47 s. Vedoucí bakalářské práce byl doc. Ing. Václav Jirsík, CSc.

Prohlášení

„Prohlašuji, že svou bakalářskou práci na téma Kohonenova síť jsem vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: **28. května 2011**

.....
podpis autora

Poděkování

Děkuji vedoucímu bakalářské práce doc. Ing. Václavovi Jirsíkovi, CSc. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé bakalářské práce.

V Brně dne: **28. května 2011**

.....
podpis autora

Obsah

1	Úvod	9
2	Samoorganizující neuronové sítě	10
2.1	Historie samoorganizujících neuronových sítí	10
2.2	Dynamika neuronové sítě.....	11
2.3	Vektorová kvantizace.....	12
2.3.1	Lloydův algoritmus	12
2.3.2	Kohonenovo učení	13
2.4	Síť ART.....	14
2.4.1	Funkce sítě ART	15
3	Kohonenova síť	16
3.1	Aktivní dynamika.....	17
3.2	Adaptační dynamika.....	17
3.2.1	Krokový postup učícího procesu	18
3.2.2	Grafický průběh učícího procesu	19
3.3	Metoda LVQ	20
3.4	Aplikace Kohonenovy sítě	21
4	Programové prostředí	22
4.1	Grafické rozhraní	22
4.2	Nastavení sítě a tréninkových dat.....	23
4.2.1	Zobrazení 2D sítě, dat a tříd.....	24
4.3	Algoritmus učení.....	24
4.4	Citlivostní analýza.....	25
5	Vliv vybraných parametrů sítě na průběh učení.....	26
5.1	Metoda citlivostní analýzy	26
5.2	Citlivostní analýza na vybrané parametry.....	28
5.3	Rozbor získaných dat	29
5.3.1	Parametr pokrytí.....	29
5.3.2	Parametr odchylky	30
5.3.3	Srovnání parametru odchylky a parametru pokrytí.....	31
5.4	Vybrané variace parametrů učení.....	32
5.4.1	Vhodnost vybraných parametrů učení.....	34

6	Problematika počátečního nastavení vah.....	37
6.1	Teoretické otázky počátečního nastavení vah.....	37
6.1.1	Modifikace Kohonenova učení	37
6.2	Vliv počátečního nastavení vah	38
6.3	Vliv volby prostoru počátečního nastavení vah	38
7	Závěr.....	42
8	Přílohy	49

1 ÚVOD

Umělé neuronové sítě zažily velmi ambiciózní nástup v 50. letech minulého století. Jejich vznik datovaný objevem jednoduchého modelu neuronu a následně neuronové sítě samotné byl motivován biologickou předlohou, tedy biologickým neuronem v centrálním nervovém systému (CNS) člověka. Pro svůj charakter, schopnost učit se a schopnost modelovat složité problémy, by našly umělé neuronové sítě široké spektrum uplatnění. Neschopnost modelovat logickou funkci XOR však odsunul neuronové sítě na druhou kolej [MP69].

Zájem o neuronové sítě se opět probudil v 80. letech, kdy byl také navržen model samoorganizující sítě a jejího učícího procesu T. Kohonenem. Sít' i učení v dnešní době nese jeho jméno a právě na jeho výzkum se primárně zaměřuje tato bakalářská práce.

Druhá kapitola se zabývá samoorganizujícími neuronovými sítěmi, mezi které patří sít' ART, popsaná v druhé kapitole, a Kohonenova sít', již je věnována třetí kapitola. Kapitola popisuje také vektorovou kvantizaci, Lloydův algoritmus, Kohonenovo učení, historii týkající se samoorganizujících neuronových sítí a dynamiku neuronových sítí.

Třetí kapitola se týká Kohonenovy sítě. V této kapitole je vysvětlena aktivní dynamika (vybavování) i adaptační dynamika (učení). Nakonec jsou zmíněny metody LVQ pro učení Kohonenovy sítě s učitelem a aplikace této sítě.


Čtvrtá kapitola je věnována programovému prostředí, jehož bylo během praktické části práce využito. V této kapitole je ukázáno grafické rozhraní a přiblížena funkce samotného programu Kohonenovy neuronové sítě. Následně je popsán grafický výstup z aplikace a specifika učení, jež byla využita při tvorbě učícího algoritmu. Do programu byl implementován nový prostředek citlivostní analýzy na parametry učení.

Pátá kapitola se podrobněji věnuje metodě citlivostní analýzy. V této kapitole je obsažen průběh citlivostní analýzy na parametry učení. Je představen soubor vybraných variací parametrů učení a poukázáno na nejvhodnější variantu.

Šestá kapitola přednáší teoretické poznatky o vlivu počátečního nastavení vah na výslednou pozici vítězného neuronu. Vlivu počátečního nastavení vah je dále analyzován a zhodnocen. Výsledkem je řada tvrzení vymezujících skutečný vliv počátečního nastavení vah.

2 SAMOORGANIZUJÍCÍ NEURONOVÉ SÍTĚ

Samoorganizující neuronové sítě jsou speciálním případem umělých neuronových sítí. Umělá neuronová síť je obecný matematický model, který je složen z jednoho nebo více formálních neuronů. Model formálního neuronu (viz. obr. 2.1) je navržen podle biologického neuronu a modeluje stavbu a funkci neuronu, coby elementární částice biologické neuronové sítě.



Obr. 2.1 Formální neuron

Formální neuron má vstupy x_1, \dots, x_n obecně reálné. Tyto vstupy mají obecně rozdílné reálné váhy w_1, \dots, w_n , které udávají propustnost jednotlivých vstupů. Vnitřní potenciál ξ je tvořen zváženou sumou hodnot vstupů. Hodnota takové sumy musí přesáhnout daný práh θ , aby se projevila na výstupu perceptronu. Práh bývá charakterizován hodnotou biasu, váhy permanentního jednotkového vstupu, $w_0 = -\theta$ pro $x_0 = 1$. Po překročení prahové hodnoty je vnitřní potenciál neuronu transformován tzv. aktivační funkcí $y = f(\xi)$ na výstup [ŠN96].

2.1 Historie samoorganizujících neuronových sítí

V roce 1943 W. McCulloch a W. Pitts vytvořili jednoduchý matematický model neuronu a ukázali světu možnost realizace matematických funkcí na základě propojení více neuronů. Od roku 1943 se tedy datuje vznik první umělé neuronové sítě. V jejich bádání dále pokračovali D. Hebb svým návrhem učicího pravidla (r. 1949), F. Rosenblatt návrhem tzv. perceptronu, který představuje zobecněný model původního neuronu pro reálný obor parametrů (r. 1957) [Ro57]. Řada dalších vědců pokročila s vývojem neuronových sítí.

Samoorganizující neuronové sítě využívají tzv. soutěžního učení. První průkopnické práce o soutěžním učení se objevovaly v šedesátých letech. Soutěžnímu učení se ve své knize věnoval již N. J. Nilsson v roce 1965 [Ni65]. V sedmdesátých letech se

soutěžnímu učení věnovala celá řada vědců. Pro modelování způsobu detekce hran v primárním optickém kortexu savců byl navržen algoritmus soutěžního učení von der Malsburgem [Ma73]. Tento algoritmus předpokládal, že zvětšení váhy jednoho neuronu způsobí zmenšení vah ostatních neuronů. Nedostatek zmíněného algoritmu byl odstraněn v práci S. Gossberga [Gr76] zabývající se adaptivním rozpoznáváním vzorů. K. Fukushima navrhl model vícevrstvé samoorganizační sítě zvané kognitron [Fu75].

Asi nejvýznamnější prací byla práce T. Kohonena. V roce 1982 navrhl Kohonenovu samoorganizační mapu. Jedná se o architekturu jednovrstvé sítě. Tato architektura je využita u Kohonenovy samoorganizační sítě, jinak Kohonenovy sítě.

2.2 Dynamika neuronové sítě

Umělá neuronová síť se skládá z množství neuronů. Jejich počet a vzájemné spojení je dáno topologií neuronové sítě. Stavem neuronové sítě myslíme stav všech neuronů v síti. Nastavení synaptických vah všech spojů udává konfiguraci neuronové sítě. Neuronová síť se v čase vyvíjí. Celková dynamika neuronové sítě se dělí do tří dynamik [ŠN96].

Organizační dynamika popisuje topologii sítě. Ta je převážně pevná. Organizační dynamika se nejčastěji projevuje přidáním či odebráním neuronu ze struktury.

Aktivní dynamika představuje změnu stavu sítě. Specifikuje tedy počáteční stav sítě a jeho časovou změnu pro pevnou topologii a konfiguraci. Aktivní dynamika udává, zda síť pracuje pomocí sekvenčního výpočtu, aktualizuje v daný časový okamžik stav pouze jednoho neuronu, nebo paralelního výpočtu, tedy stavy více neuronů. Také říká, jestli jsou tyto stavy aktualizovány nezávisle na sobě nebo centrálně, tedy jedná-li se o asynchronní nebo synchronní model neuronové sítě.

Adaptivní dynamika charakterizuje změnu konfigurace. Adaptivní dynamika zahrnuje počáteční konfiguraci sítě a způsob její časové změny. Specifikuje-li aktivní dynamika chování stavu pro pevnou konfiguraci, adaptivní dynamika hledá správnou konfiguraci vah sítě tak, aby realizovala požadovanou funkci v aktivní dynamice. Tento proces nazýváme učení.

Samoorganizující neuronové sítě využívají učení bez učitele. To znamená, že tréninková množina neobsahuje žádané výstupy na tréninkové vstupní vektory. Učení bez učitele bývá také nazýváno vektorová kvantizace. Dále je v kapitole 2.3.1 uveden klasický Lloydův algoritmus. Jednoduchá varianta soutěžního učení, nazvaná Kohonenovo učení, je představena v kapitole 2.3.2.

2.3 Vektorová kvantizace

Pomocí vektorové kvantizace se aproximuje hustota pravděpodobnosti $p(x)$ reálných vstupních vektorů pomocí konečného počtu neuronů s reálnými vahami \mathbf{w}_i ($i=1,\dots,m$). Po počáteční nastavení vah je každému vstupnímu vektoru \mathbf{x} vyhledán ten nejbližší neuron s váhovým vektorem \mathbf{w}_c :

$$c = \arg \min_{l=1..h} \{\|\mathbf{x} - \mathbf{w}_l\|\} \quad (2.1)$$

Možným způsobem, který pomůže najít správný neuron je výpočet a minimalizace chyby ve tvaru:

$$E = \int \|\mathbf{x} - \mathbf{w}_c\|^2 p(\mathbf{x}) d\mathbf{x} \quad (2.2)$$

Pravděpodobnostní rozložení však bývá v praxi neznámé a je charakterizováno tréninkovou množinou $T=\{\mathbf{x}^{(t)}; t=1,\dots,p\}$, což přeformuluje výpočet chyby do následujícího vztahu:

$$E = \frac{1}{p} \sum_{t=1}^p \|\mathbf{x}^{(t)} - \mathbf{w}_c\|^2 \quad (2.3)$$

Protože hodnota chyby je funkčně závislá na vzorech \mathbf{x} i vahách neuronů \mathbf{w} , není snadné vyjádřit gradient chyby. Za tímto účelem byl vyvinut základní Lloydův algoritmus [ŠN96].

2.3.1 Lloydův algoritmus

Je-li problém zadán tréninkovou množinou T a známe m počet neuronů, jsme schopni provádět následující algoritmus, který vede ke snížení hodnoty chyby pod předem zadanou mez ε . Po počátečním nastavení váhových vektorů \mathbf{w}_i se provádí následující kroky:

1. Každému vzoru $\mathbf{x}^{(t)}$ tréninkové množiny $T=\{\mathbf{x}^{(t)}; t=1,\dots, p\}$ je přiřazen příslušný neuron s vahou \mathbf{w}_c podle vztahu (2.1).
2. Spočte se chyba E pomocí (2.3).
3. Jestliže je chyba menší než zadaná mez ε , ukončí se algoritmus.
4. Pro každé $j = 1, \dots, m$ proběhne výpočet těžiště t_j množiny T_j :

$$t_j = \frac{1}{|T_j|} \sum_{\mathbf{x}_j \in T_j} \mathbf{x}_j, \quad (2.4)$$

kde platí:

$$T_j = \{\mathbf{x}^{(t)}; j = \arg \min_{l=1..m} \{\|\mathbf{x}^{(t)} - \mathbf{w}_l\|\}\}. \quad (2.5)$$

5. Následuje přiřazení $\mathbf{w}_j = \mathbf{t}_j$.
6. Opakování cyklu od 1. kroku.

Výstupem algoritmu jsou hodnoty vah jednotlivých neuronů \mathbf{w}_j , $j = 1, \dots, m$. Nevýhodou tohoto algoritmu je aktualizace hodnot váhových vektorů \mathbf{w}_j až po průchodu celou množinou, což zpomaluje výpočet. Jednoduchá on-line varianta tohoto algoritmu je Kohonenovo učení, které provádí změnu váhového vektoru vítězného neuronu po každém předložení testovacího vzoru [ŠN96].

2.3.2 Kohonenovo učení

Kohonenovo učení pracuje s jednovrstvou sítí s úplným propojením mezi neurony a vstupy. Vrstva neuronů se skládá z neuronů, které plní funkci reprezentantů tříd. Váha \mathbf{w}_j každého neuronu $j = 1, \dots, m$ určuje jeho polohu ve vstupním prostoru [ŠN96].

Aktivní dynamika sítě se řídí následujícími pravidly. Vstupy \mathbf{x} mohou být libovolná reálná čísla. Výstupy y_j nabývají reálných hodnot:

$$y_j^{(t)} = \begin{cases} 1 & j = \arg \min_{l=1..m} \{\|\mathbf{x}^{(t)} - \mathbf{w}_l\|\} \\ 0 & \text{jinak} \end{cases} \quad (2.6)$$

Uvedený vztah ukazuje, že hodnota 1 (aktivní) je přiřazena právě tomu výstupnímu neuronu, který je vybrán jako nejbližší vstupnímu vzoru. Aktivuje se vždy právě jeden neuron. Tomuto principu říkáme „vítěz bere vše“. Mechanismus se nazývá laterální inhibice.

Sama adaptivní dynamika pro Kohonenovo učení pracuje následovně. Postupně jsou předkládány všechny vzory tréninkové množiny. Pro každý vzor se vybere nejbližší neuron z vrstvy. Váhy takového neuronu jsou upraveny následujícím předpisem:

$$w_{ji}^{(t)} = \begin{cases} w_{ji}^{(t-1)} + \mu(x_i^{(t-1)} - w_{ji}^{(t-1)}) & j = \arg \min_{l=1..h} \{\|\mathbf{x}^{(t)} - \mathbf{w}_l\|\} \\ w_{ji}^{(t-1)} & \text{jinak} \end{cases} \quad (2.7)$$

μ značí parametr učení. Na začátku učení je zpravidla blízký hodnotě 1 a postupně klesá. Jeho minimální hodnota je 0.

V projekci do roviny vstupních dat takto popsaným postupem dochází ke zlepšení pozice nejbližšího neuronu vůči aktivnímu tréninkovému vzoru.

2.4 Síť ART


Zkratka ART má po překladu význam adaptivní rezonanční teorie. Síť ART byla navržena S. Grossbergem v roce 1976. Byla dále rozpracována o deset let později ve spolupráci s G. Carpenterem.

Síť Art má jednu zásadní vlastnost. Dokáže dobře řešit problém proměnné stability. Na rozdíl např. od vícevrstvé perceptronové sítě, u které může dojít změnami vah během učení nového vzoru ke zhroucení celé sítě a ztrátě všech informací.

Jedná se o asociativní síť bez učitele, která se dokáže přepínat mezi tvárným a stabilním módem, aniž by pak došlo k poškození již naučených informací. Stabilní mód neumožňuje zápis nové informace a síť v něm pracuje jako již naučená, tedy jako klasifikátor. Naopak v tvárném módu je umožněna změna parametrů sítě. Síť ART má navíc dobrou citlivost na kontext a dokáže eliminovat špatné informace [MŠL93b].

Bylo navrženo několik variant sítě ART. ART1 pracuje s binárními hodnotami vstupů. ART2 má stejnou dynamiku s tím rozdílem, že je navržena pro práci s reálnými hodnotami. ART3 má strukturu popsanou rovnicemi, jež zaznamenávají i dynamiku chemických přenašečů informace [MŠL93b].

Model této sítě staví na dvouvrstvé architektuře (obr. 2.2), vrstvy porovnávací (vstupní) a rozpoznávací (výstupní). Vzájemné spojení je zajištěno prostřednictvím dopředných w_{ij} a zpětných t_{ij} vah. Ty spojují $i = 1, \dots, n$ vstupních neuronů s $j = 1, \dots, m$ výstupních neuronů. Neurony rozpoznávací vrstvy jsou navíc spojeny mezi sebou. Každé vrstvě náleží řídicí signály 1 a 2. Nezbytnou součástí je tzv. nulovací člen, který rozhoduje, zda pro vzor již existuje třída, nebo má být vytvořena třída nová.



Obr. 2.2 Architektura sítě ART [MŠL93b].

2.4.1 Funkce sítě ART

Síť ART má během své práce fáze: inicializační, rozpoznávací, pozorovací, vyhledávací a adaptační. Ty jsou stručně popsány v následujících odstavcích [MŠL93b].

Inicializační fáze

Během inicializační fáze jsou řídicí signály nastaveny na příjem dat a dojde k počátečnímu nastavení zpětných vah $t_{ij} = 1$ a dopředných vah $w_{ij} = 1/(1+n)$.

Rozpoznávací fáze

Neurony rozpoznávací vrstvy mají tři vstupy: element x_i , zpětná vazba porovnávací vrstvy a řídicí signál 1. Pomocí tzv. dvoutřetinového pravidla se každý vstupní neuron rozhoduje o své aktivitě. To znamená, že při aktivitě alespoň dvou vstupů je aktivní i daný neuron, v opačném případě, je neaktivní.

Vstupní vektor je tímto způsobem přenesen a transformován dopřednými vahami. Na rozpoznávací vrstvě se jako v případě Kohonenova učení vyhledá nejlepší adept. Vlivem laterální inhibice je nejlepší adept posílen a ostatní jsou potlačeni.

Porovnávací fáze

Rozpoznávací fáze poskytla informaci o rozpoznaném reprezentantu. Zároveň je přítomna informace o vstupním vektoru. Tyto informace jsou zpracovány porovnávací vrstvou a vyhodnoceny nulovacím členem. Nulovací člen rozhoduje o tom, zda předložený vstupní vektor odpovídá předloženému reprezentantovi.

Vyhledávací fáze


Postup porovnávací fáze je opakován do nalezení úspěšného reprezentanta nebo vyčerpání možných kandidátů. V případě, že vhodný reprezentant nebyl nalezen, je vytvořen nový neuron rozpoznávací vrstvy a jsou mu přiřazeny hodnoty vstupního vektoru, tedy nové třídy.

Adaptační fáze

Prošel-li vzor testem bdělosti, jsou zpětné i dopředné váhy reprezentanta přizpůsobeny podle tohoto vzoru. Test bdělosti spočívá ve srovnání míry odlišnosti trénovacího vzoru a nejbližšího reprezentanta. Úspěšný test ukazuje na dostatečnou odlišnost tréninkového vzoru a nejbližšího reprezentanta.


3 KOHONENOVA SÍŤ

Kohonenova síť je nejvýznamnějším zástupcem samoorganizujících sítí. Byla navržena v roce 1982 T. Kohonenem. Topologie této sítě se nazývá Kohonenova samoorganizující mapa a neurony jsou organizovány v tzv. kompetiční vrstvě.



Obr. 3.1 Architektura Kohonenovy sítě.

Tato vrstva je naplněna neurony, kde každý neuron má přístup k informaci každého z n vstupů x_i , $i = 1, \dots, n$. Neurony a vstupy jsou spojeny prostřednictvím vah. Váhy mají charakter souřadnice vlastního neuronu ve vstupním prostoru. Navíc mají tyto neurony mezi sebou postraní vazby. Pomocí postraních vazeb jsou neurony uspořádány do zvolené topologické mřížky. Podle zvolené topologie se liší tzv. okolí neuronu. Toto okolí vymezuje sousední neurony zvoleného neuronu (obr. 3.2).



Obr. 3.2 Možné topologie okolí neuronů v kompetiční vrstvě: čtvercová (vlevo), hexagonální (vpravo) [Vj06].

3.1 Aktivní dynamika

V aktivním režimu dochází ke stejnému vybavování jako v případě Kohonenova učení (viz kapitola 2.3.2). Předpokládáme již naučenou síť. Neurony kompetiční vrstvy spolu soutěží, který je nejbližší vstupnímu vektoru. Vítěz této kompetice následně aktivuje pouze sebe a výstup sítě je roven výstupu aktivního neuronu. Tento neuron představuje reprezentanta třídy, do níž byl sítí vzor zařazen.

V krocích je tento proces popsán následovně:

1. Na vstup se přiloží vstupní vektor $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$.
2. Proběhne výpočet vzdáleností d_j mezi každým neuronem v kompetiční vrstvě a vstupním vektorem:

$$d_j = \sum_{i=1}^n [x_i(t) - w_{ij}(t)]^2. \quad (3.1)$$

3. Dojde k výběru vítězného neuronu na základě nejmenší vzdálenosti d_{j^*} .

$$d_{j^*} = \min_j(d_j) \quad (3.2)$$

4. Vybraný neuron, tedy vítěz, aktivuje svůj výstup, čímž zařadí předložený vstupní vektor do svojí třídy. V tomto kroku lze podle literatury rozlišit dva režimy.

Neadaptační režim nedovolí úpravu konfigurace naučené sítě, pouze zařadí vstupní vektor do odpovídající třídy.


V **Adaptačním režimu** zařadí vstupní vektor jako v případě neadaptačním, ale následně dovolí malou modifikaci vah vítězného neuronu a jeho okolí, tzv. přiučování [ŠN96].

3.2 Adaptační dynamika

Adaptační dynamika Kohonenovy sítě modifikuje během učení váhy neuronů kompetiční vrstvy jako reakci na přikládání vstupní vektory vzorů z tréninkové množiny. Následkem takového procesu je uspořádání neuronů tak, aby jejich rozložení co možná nejlépe kopírovalo pravděpodobnostní rozdělení předloženého problému. To umožní přesnější klasifikaci předložených dat během rozpoznávání.

Adaptace sítě probíhá po krocích. Vždy pro jeden tréninkový vzor je vybrán nejbližší neuron. U takového neuronu, vítěze kompetice, dojde k pozitivní modifikaci vah směrem k souřadnicím vzoru. Zároveň dochází k úpravě vah okolních neuronů.

Jakým způsobem dojde k modifikaci okolí aktivního neuronu, závisí na tvaru adaptační funkce (obr. 3.3).



Obr. 3.3 Adaptivní funkce okolí neuronu j : biologická (vlevo), zjednodušená (vpravo)

3.2.1 Krokovaný postup učícího procesu

1. Inicializace sítě zahrnuje nastavení počátečních hodnot parametru učení μ_0 a okolí ρ_0 , dále počáteční nastavení vah. Je několik možností, jak na začátku učení nastavit váhové vektory výstupních neuronu. Tímto problémem se budeme hlouběji zabývat v kapitole 5.
2. Po inicializaci následuje předložení vzoru $\mathbf{x}(t) = \{x_1(t), x_2(t), \dots, x_n(t)\}$ z trénovací množiny $T = \{\mathbf{x}(t); t=1, \dots, k\}$ na vstup sítě, kde k značí počet vzorů trénovací množiny.
3. Pro aktuální vzor se hledá nejbližší neuron, stejně jako v případě aktivace. Podle vztahu (3.1) se tudíž spočte vzdálenost vzoru od každého neuronu kompetiční vrstvy.
4. Výběr nejpodobnějšího neuronu j^* proběhne na základě formule (3.2).
5. Po výběru dojde k modifikaci vah neuronu j^* a všech neuronů patřících do jeho okolí $\rho_j(t)$ podle rovnice:

$$w_{ij}(t+1) = w_{ij}(t) + \mu(t) (x_i(t) - w_{ij}(t)). \quad (3.3)$$

S postupem cyklů učení klesá parametr učení μ , čímž se plynule přechází od tzv. hrubého naučení k učení jemnému. Předchozí kroky 2 až 5 se provedou pro všechny vzory testovací množiny.

6. Po každém cyklu učení testovací množiny dojde k aktualizaci učících parametrů. Parametr učení se zmenší o zvolené ε :

$$\mu(t+1) = \mu(t) - \varepsilon. \quad (3.4)$$


Jedná-li se o zjednodušenou adaptační funkci, okolí ρ aktualizuje svoji hodnotu skokově o jedna po zvoleném počtu cyklů s periodou τ :

$$\rho(t+\tau) = \rho(t) - 1. \quad (3.5)$$


7. Algoritmus učení může být ukončen na základě mezní hodnoty Φ parametru učení nebo po určitém počtu iteračních cyklů N . Po dobu, kdy není naplněna některá z uvedených podmínek ukončení učení, se opakují kroky 2 až 6 [MŠL93b].

3.2.2 Grafický průběh učícího procesu


Rozvinování neuronové mřížky začíná náhodným nastavením vah vstupních dat (obr. 3.4). Postupně dochází k rozvinování mřížky v prostoru vstupních dat pro vysoké hodnoty učícího parametru (obr. 3.5), dále pro nízké hodnoty učícího parametru (obr. 3.6). Konečný stav mřížky pro naučenou síť vidíme na obr. 3.7.




Obr. 3.4 Inicializované váhy



Obr. 3.5 Rozvinování mřížky




Obr. 3.6 Rozvinování mřížky




Obr. 3.7 Konečný stav mřížky

Během učení Kohonenovy sítě může dojít k částečnému nebo úplnému překroucení mřížky sítě. Překroucení mřížky způsobuje znehodnocení naučené sítě a je omezena nebo znemožněna správná funkce neuronové sítě. Grafický záznam částečně překroucené mřížky (zvýrazněno silnou křivkou) poskytne obr. 3.9. Překroucená mřížka je na obr. 3.10.



Obr. 3.8 Překroucená mřížka



Obr. 3.9 Částečně překroucená mřížka

3.3 Metoda LVQ

Learning Vector Quantization, česky učící vektorová kvantizace, se využívá jako modifikace Kohonenovy sítě pro učení s učitelem. Tato úprava umožňuje Kohonenově síti označit výstupní neurony kategoriemi a doučit se pro přesnější třídění.

Učení budeme uvažovat ve třech fázích:

1. Učení bez učitele (stejně jako pro běžnou Kohonenovu síť, kapitola 3.2.1).
2. Označení výstupních neuronů kategoriemi.
3. Následné doučení jednou z variant LVQ algoritmů.

První fáze analogicky odpovídá učení v klasické Kohonenově síti. Ve druhé fázi je z tréninkové množiny $T=\{(\mathbf{x}(t), d(t)); t=1, \dots, k\}$ využita také hodnota požadovaného výstupu pro každý vzor. Každému vzoru je vyhledán prostřednictvím známé kompetice nejpodobnější váhový vektor neuronu a ten dostane přiřazenu kategorii $d(t)$. Po průchodu tréninkovou množinou má každý neuron přiřazeno více kategorií. Pro jednotlivé neurony je spočtena četnost přiřazení k dané kategorii a tu nejčastější označíme v_j . Takto se vytvoří skupiny neuronů. Tyto skupiny odpovídají jednotlivým kategoriím. Poslední fáze odpovídá algoritmu buď LVQ1, LVQ2 nebo LVQ3 [ŠN96].

LVQ1

Tento algoritmus vyhledá testovacímu vzoru nejpodobnější neuron a ověří, zda jeho kategorie odpovídá té vzorové. Je-li tomu tak, neuron lehce posílí svoji pozici vůči vzoru, v opačném případě je od vzoru stejnou měrou odstrčen. Zapsáno:

$$w_{ij}(t+1) = \begin{cases} w_{ij}(t) + \alpha(x_i(t) - w_{ij}(t)) & d(t) = v_j \\ w_{ij}(t) - \alpha(x_i(t) - w_{ij}(t)) & d(t) \neq v_j \end{cases} \quad (5.6)$$

LVQ2

Pro případ LVQ2 dochází navíc k ovlivňování druhého neuronu. Jsou nalezeny dva neurony, nejbližší správný a nejbližší špatný. Stejným vztahem jako u LVQ1 odsuneme špatně kategorizovaný a přisuneme dobrý. To má ale i negativní dopad, protože algoritmus se neptá, který z neuronů je opravdu nejbližší.


LVQ3

LVQ3 se snaží odstranit negativa LVQ2 tak, že navíc ostatním správně klasifikujícím neuronům dané kategorie posílí pozici vůči aktuálnímu vzoru.

3.4 Aplikace Kohonenovy sítě

Jak je běžně zmiňováno, Kohonenova síť skýtá široké možnosti využití. V literatuře se setkáme s aplikacemi v medicíně, zpracování řeči (např. součást NETtalk), zpracování obrazu. Dobře uplatnitelná je tato síť při vyhledávání osob a objektů na videích a obrázcích. Z toho plynou bezpečnostní aplikace a hledání osob. Dokáže najít podobné znaky mezi nepřímo souvisejícími daty, proto má dobré uplatnění v ekonomii, kde dokáže sledovat např. společné znaky spotřebitelů, a tak na ně upozornit marketing [MŠL93a].

V českém prostředí byla Kohonenova síť aplikována při diagnóze neurologických onemocnění u dětí na základě řečového projevu jedince. Vícevrstvou Kohonenovou sítí došlo k naučení rozděleného a parametrizovaného zvukového záznamu a vyhodnocení [Tu08].



**Obr. 3.10 Kohonenova samoorganizující mapa:
zdravé dítě (vlevo), nemocné dítě (vpravo)**

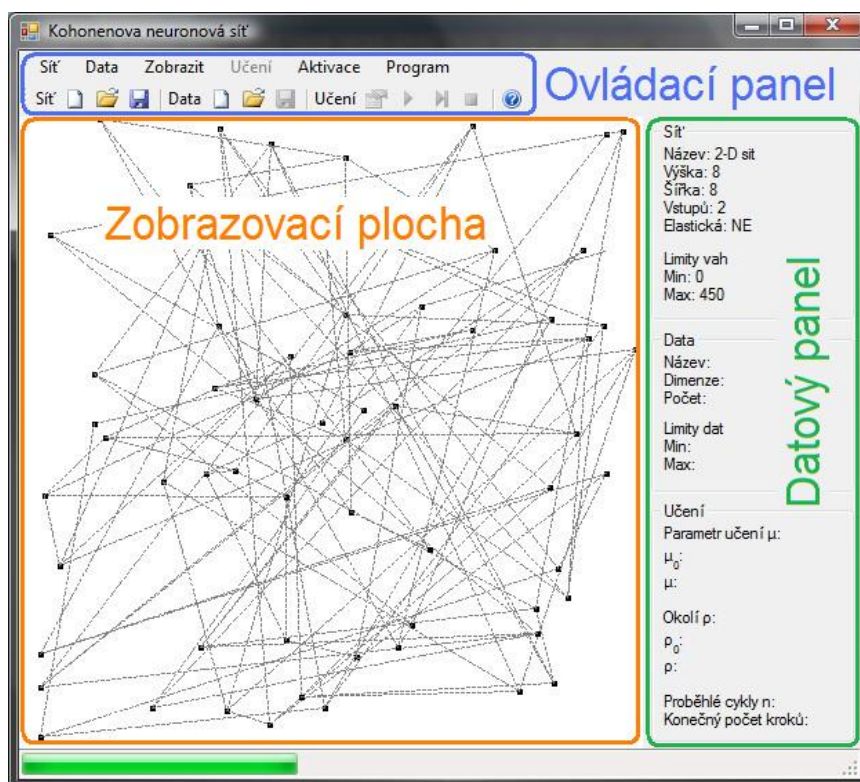
4 PROGRAMOVÉ PROSTŘEDÍ

Na ústavu automatizace a měřicí techniky Fakulty elektrotechniky a komunikačních technologií VUT v Brně byl pod vedením doc. Ing. Václava Jirsíka, CSc. navržen a realizován program Kohonenovy neuronové sítě. Návrhem a vytvořením programu se zabýval Bc. Viktor Žáček v rámci své semestrální práce [Žá12].

Tento program byl zvolen jako vhodný prostředek pro naplnění úkolů zadání této bakalářské práce. Testování programu proběhlo ve verzi 1.3. Nyní bude následovat stručný popis samotné aplikace, jejího grafického rozhraní a kmenových funkcí, které nesou značný význam pro výzkum samotného vlivu počátečního nastavení vah a dalších parametrů.

4.1 Grafické rozhraní

Grafické uživatelské rozhraní (GUI) aplikace „Kohonenova neuronová síť“ je vytvořeno velmi intuitivně, a proto se v něm dá snadno a rychle zorientovat, viz obr. 4.1.




Obr. 4.1 Popis GUI programu Kohonenova neuronová síť.

Ovládací a datový panel jsou rozměrově pevně dány, ale zobrazovací plocha se přizpůsobuje, což je velkou výhodou pro rozsáhlejší sítě. Ukažme si cestu až k rozběhnutí početního algoritmu.


4.2 Nastavení sítě a tréninkových dat

Aplikace nabízí prostřednictvím menu „Sít“ vytvoření nové Kohonenovy sítě hned několika způsoby, v této práci bude téměř výhradně využita varianta 2D sítě. Následně lze síť uložit a později načíst ve formátu .knn z podadresáře aplikace /Net.




Obr. 4.2 Menu Sít.

S tréninkovými daty pro učení sítě se pracuje přes menu „Data“. Data je možné generovat automaticky na daném rozsahu v prostoru, zadat ručně, nebo pomocí kurzoru na zobrazovací plochu. Nechybí ani obvyklé operace uložení a načtení dat (format .dat).



Obr. 4.3 Menu Data


Po načtení, příp. vytvoření, sítě a dat je třeba nastavit počáteční hodnoty učících parametrů. K tomu slouží menu „Učení“, kde se nachází také možnost průběžného vykreslování průběhu učení a tlačítka spuštění a krokování učení.



Obr. 4.4 Tlačítka řízení učení

4.2.1 Zobrazení 2D sítě, dat a tříd

Stiskem menu „Zobrazit“ se rozvine celá paleta možností. Kromě variant testového výpisu sítě a dat, je tu také 2D vykreslení sítě, dat a okolí neuronu. Dokonce lze ukázat vrstvy mapy nebo U-matrix a v případě trojrozměrné sítě RGB ohodnocení neuronů sítě. Na zobrazovací ploše můžeme vykreslit 2D „pozice“ neuronů a spojení v topologii (mřížku), vstupní data a také třídy (oblasti) vstupních dat reprezentované vybraným neuronem (viz obr. 4.5).



Obr. 4.5 Příkladové vykreslení sítě, dat, tříd na zobrazovací ploše.

Tréninková data jsou znázorněna zelenými kružnicemi. Neuron reprezentuje v zobrazení černá tečka. Aby bylo možné sledovat vazby mezi neurony v topologii, kreslí se na místo jednotlivých spojení přerušovaná černá čára. To jak síť pokrývá prostor vstupních dat, prezentují jednotlivé třídy, na které je prostor dat rozdělen. Hranice tříd značí fialové hrany obrazu. Aktivací vstupním vektorem spadajícím do některé z vybraných tříd je aktivován výstup nejbližšího neuronu.

4.3 Algoritmus učení

Síť realizovaná tímto programem má čtvercovou topologii s voleným počtem neuronů. V této kapitole jsou uvedeny odlišnosti naprogramovaného algoritmu a algoritmu učení Kohonenovy sítě popsaného v kapitole 3.2.1, které se týkají zvolených průběhů parametru učení μ a okolí ρ .

Parametr učení má exponenciální závislost na počtu cyklů. Dáno vztahem:

$$\mu(n) = \mu_0 \cdot e^{-kn}, \quad (4.1)$$

kde μ_0 je počáteční hodnota parametru učení, volena blízká jedné, n počet proběhlých cyklů $n \in \mathbb{N}^0, n \in \{0, 1, 2, \dots, N\}$ a k koeficient exponenciály. Parametr učení μ má

během několika prvních cyklů relativně velký spád, který nastavíme velikostí koeficientu k .

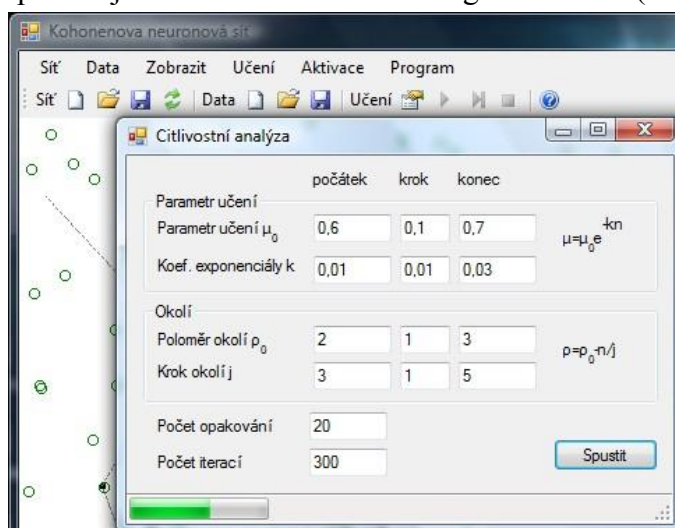
Okolí ρ se také během učení mění. Jeho závislost je vyjádřena ve tvaru:

$$\rho(n) = \rho_0 - \frac{n}{j}, \quad (4.2)$$

kde ρ_0 nese počáteční hodnotu okolí a j krok okolí, přičemž jako velikost okolí $\rho(n)$ se bere vždy celočíselná část hodnoty.

4.4 Citlivostní analýza

Původní program vytvořený Bc. Viktorem Žáčkem poskytoval výstupy ve formě hodnot vah ve výsledném stavu sítě. To je nevhodné pro využití na rozsáhlejší analýzu vlivu jak parametrů učení, tak počátečního nastavení vah na průběh učení a konečné pozice neuronů v síti. Proto byla navržena metoda analýzy a následně konzultována s autorem programu. Tento prostředek byl následně zakomponován do původní aplikace Kohonenova neuronová síť. Lze jej najít v menu „Učení“ pod položkou „Citlivostní analýza“. Po poklepání dojde k otevření nového dialogového okna (obr. 4.6).



Obr. 4.6 Okno Citlivostní analýza

Okno vyžaduje do kolonek doplnění počátečních, konečných hodnot a kroku vybraných parametrů. Počet opakování a počet iterací (učících cyklů) je pro analýzu neproměnlivý. Časový průběh citlivostní analýzy znázorňuje progres bar umístěný ve spodní části okna. Po vyplnění vybraných kolonek můžeme pokračovat pomocí Spustit. Kliknutím je vyvolán požadavek na umístění datového souboru ve formátu *název.xls* (sešit aplikace Microsoft Office Excel 2003). Po dokončení analýzy je žádán přepis předvytvořeného souboru *název.xls*. Potvrzením se uloží na dané místo data vyhotovené analýzy.

5 Vliv vybraných parametrů sítě na průběh učení

Proces učení Kohonenovy neuronové sítě je ovlivněn mnoha parametry. Mezi ty, které volíme a můžeme ovlivnit, patří parametr učení μ_0 , koeficient exponenciály k , okolí neuronu ρ_0 , krok okolí j . Co ještě lze ovlivnit, je prostor počátečního nastavení vah. Problematikou počátečního nastavení vah se zabývá kapitola 6. Vliv některých proměnných lze zkoumat jen obtížně, např. rozložení tréninkových dat, počáteční hodnoty vah, protože se právě tyto dva prvky doporučují volit náhodně, tedy náhodné hodnoty vah a náhodný výběr z tréninkové množiny.

5.1 Metoda citlivostní analýzy

Za účelem ohodnocení chování Kohonenovy sítě v průběhu učení a ohodnocení výsledné konfigurace Kohonenovy sítě byly vytvořeny dva parametry.

Parametr odchylky Δ_s


Parametr odchylky Δ_s má za účel vytvořit představu o vlivu počátečního nastavení vah sítě na výsledné „pozice“ neuronů. Jedná se o jedinou hodnotu pro danou variaci parametrů učení zvolené sítě a tréninkových dat. Hodnota parametru odchylky Δ_s je získána podle vztahu:

$$\Delta_s = \frac{1}{O} \sum_{l=0}^O \sqrt{\frac{1}{m-1} \sum_{j=0}^m \sum_{i=0}^n (w_{lji} - \bar{w}_{ji})^2}, \quad (5.1)$$


kde O je počet opakování učení, n je rozměr vstupních dat, m je počet neuronů sítě, w_{lj} je váha j -tého neuronu v l -tém opakování a \bar{w}_{ji} je průměrná váha j -tého neuronů pro všechna opakování („střední pozice“ neuronu).

Při výpočtu parametru odchylky se projeví problém, kdy stejný neuron nemá pro všechna opakování přibližně stejnou výslednou pozici ve stavovém prostoru, ale dochází k převrácení a otáčení mřížky vůči osám a středu stavového prostoru. Výsledky testu uvedeného algoritmu tyto jevy dokazují (graf 5.1).

Graf 5.1 uvádí hodnoty parametru odchylky, tedy odchylek „pozic“ jednotlivých neuronů od jejich „střední pozice“. Data byla generována náhodně na rozsahu 0 až 450 pro dva vstupy. Parametry učení měly hodnoty $\mu_0=0,8$; $k=0,06$; $\rho=6$; $j=10$. Sít' měla topologii znázorněnou na obr. 5.1.



Graf 5.1 Parametr odchylky jednotlivých neuronů.



Obr. 5.1 Topologie Kohonenovy sítě 8x8 neuronů.

Pro dané parametry učení a danou trénovací množinu zaručeně nedocházelo k překroucení mřížky. Vysvětlit průběh hodnot parametru odchylky jednotlivých neuronů uvedených v grafu 5.1 můžeme jedinečně otočením nebo převrácením mřížky v průběhu učení v závislosti na počátečním nastavení vah.

Za účelem správného ohodnocení výsledných „pozic“ vítězných neuronů jsou zavedeny transformace. Uložením w_{ij} pro $i=1, \dots, n$ souřadnice rohových neuronů mřížky pro první opakování učení je určeno, jak bude následně uvažováno „správné“ natočení mřížky. Pro další opakování vždy provedeme porovnání w_{ij} rohových neuronů s prvním opakováním a podle typu otočení nebo převrácení transformujeme matici váhových vektorů naučené sítě tak, aby se jednotlivé neurony promítly na stejném místě mřížky jako v prvním opakování.

Aplikujeme-li výpočet parametru odchylky na transformovaný soubor výsledných stavů sítě, získáme již hodnotnou informaci o vlivu počátečního nastavení vah. Při hodnocení je menší hodnota parametru odchylky lepší než hodnota vyšší.

Parametr pokrytí Δ_d

Hodnota parametru pokrytí Δ_d , která značí míru naučení na předložená tréninková data, jako průměrná vzdálenost tréninkových vzorů od nejbližšího neuronu, je dána vztahem:

$$\Delta_d = \frac{1}{O} \sum_{l=1}^O \frac{1}{N} \sum_{i=1}^N D_{lk}(j^*), \quad (5.2)$$

kde O je počet opakování učícího procesu, N je počet tréninkových vzorů, $D_{lk}(j^*)$ je vzdálenost k -tého učícího vzoru od nejbližšího neuronu j^* při l -tém opakování. U parametru pokrytí platí, že menší hodnota parametru pokrytí je lepší.

Ve výstupním souboru *.xls* jsou uvedeny pro každou variaci parametrů učení vždy parametr odchylky Δ_s („rozptyl sítě“), parametr pokrytí Δ_d („rozptyl pokrytí“), konečná hodnota parametru učení μ a konečná hodnota okolí ρ .

	A	B	C	D	E	F	G	H
1	Iteraci	300						
2	Opakovan	20						
3	Rozměr sítě 8*8							
4	Počet vzorů	214						
5								
6	μ	koef. k	ρ	krok okolí	konečné μ	konečné ρ	rozptyl pokrytí	rozptyl sítě
7	0,55	0,01	2	3	0,0276581	0	14,80089863	41,656182
8	0,55	0,01	2	4	0,0276581	0	14,64915508	35,2115937
9	0,55	0,01	2	5	0,0276581	0	14,75553708	35,8018872

Obr. 5.2 Formulář datového výstupu citlivostní analýzy Excel.

5.2 Citlivostní analýza na vybrané parametry


Během vlastní citlivostní analýzy na parametry učení byl z důvodu rozsáhlosti problému pevně zvolen prostor počátečního nastavení vah, který odpovídal plnému rozsahu prostoru vstupních dat. Přes doporučení literatury nastavovat počáteční váhy na hodnoty blízké nule, bylo prováděno počáteční nastavení vah jinak, protože v tomto případě je Kohonenova síť analyzována na vliv parametrů učení, nikoliv použita na řešenou problematiku. Náhodné nastavení vah na celém prostoru vstupních dat zvýrazní některé aplikačně nevhodné variace parametrů prostřednictvím parametru odchylky a parametru pokrytí během citlivostní analýzy (viz kapitola 5.1).

Citlivostní analýza proběhla pro proměnné parametry učení μ_0 , k , ρ_0 a j dle hodnot v tabulce 5.1 od počáteční hodnoty do konečné hodnoty parametru po zvoleném kroku. Proběhlo vždy 20 opakování učení s 300 cykly učení.

Tab. 5.1 Parametry citlivostní analýzy

Parametr	Hodnota parametru		
	Počáteční	Krok	Konečná
μ_0	0,05	0,05	1
k	0,01	0,02	0,67
ρ_0	2	1	6
j	3	1	18

Citlivostní analýza proběhla pro síť se čtvercovou topologií 8x8 neuronů. Tréninková množina byla zvolena ve dvojrozměrném prostoru na intervalu $\langle 0, 450 \rangle$ pro oba rozměry. Celkový počet tréninkových vzorů byl 214 vstupních vektorů, nabývajících reálných hodnot. Rozložení tréninkových vzorů je na obrázku 5.3. Jedná se o náhodně generovanou množinu vzorů se třemi výraznými shluky.

**Obr. 5.3 Rozložení tréninkových dat ve vstupním prostoru.**

5.3 Rozbor získaných dat


Citlivostní analýza poskytla velké množství dat. Ukázka výstupu citlivostní analýzy se nachází v příloze D. Nejprve, aby bylo možné nějakým způsobem zvolit vhodné variace parametrů, byly odebrány intervaly parametrů pro volbu nevhodné.

5.3.1 Parametr pokrytí

Prostředkem k vyřazení značného množství variací bylo vykreslení závislosti parametru pokrytí na variacích parametrů učení vždy pro zvolené μ_0 .

V grafu 8.2 se pro koeficient $k=0,01$ a $0,03$ pohybuje parametr pokrytí kolem minimální hodnoty. Hodnota minima je dána vstupními daty, tedy pro každý předložený problém bude jiná. Protože jsou hledány hodnoty parametru pokrytí pokud možno


nejmenší, variace parametrů pro koeficient $k > 0,07$ byly zanedbány pro další výběr, neboť se minimu pouze přibližují pro malé okolí neuronu a malý krok okolí, což jak se dále ukáže, je nevhodný případ.



Graf 5.2 Závislost parametru pokrytí na rostoucím koeficientu k .

5.3.2 Parametr odchylky

Parametr odchylky je také závislý na variaci parametrů sítě. Tato hodnota vymezuje, jak velký vliv má náhodné počáteční nastavení vah na konečnou pozici neuronů pro dané parametry sítě. V grafu 5.3 je pro stejnou množinu parametrů učení jako u grafu 5.2 vykreslen parametr odchylky.



Graf 5.3 Závislost parametru odchylky na rostoucím koeficientu k .

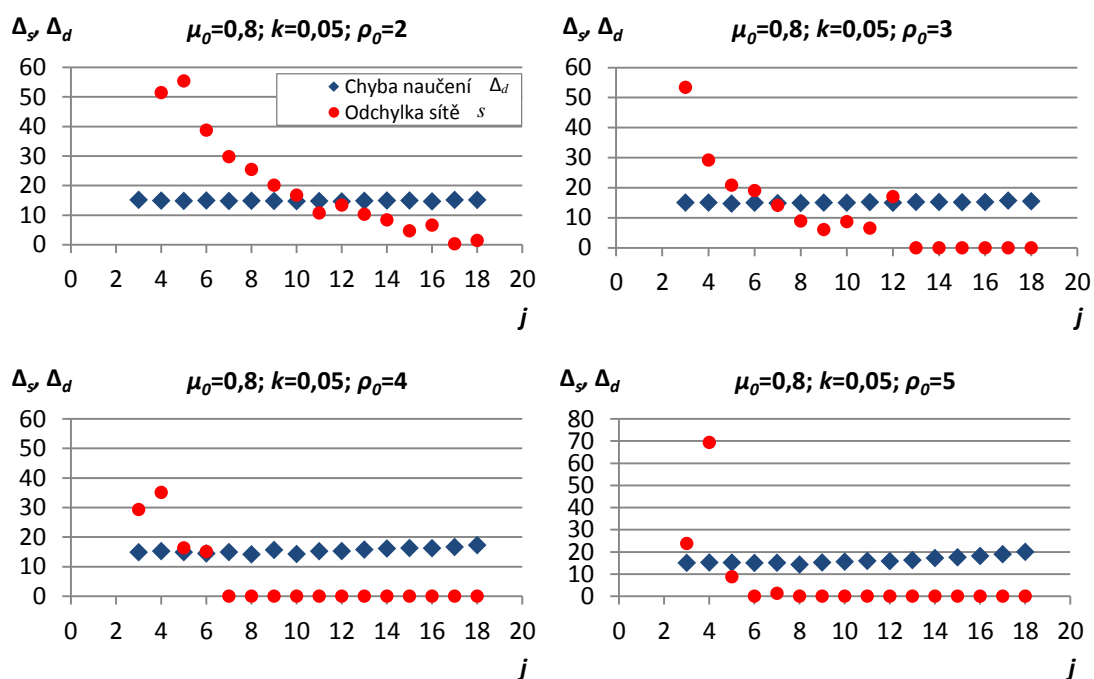
Ze závislosti parametru odchylky a parametru pokrytí na variacích parametrů vyplývá, že existuje rozpor mezi parametrem odchylky a pokrytí. Tento rozpor spočívá v následujícím.

Síť se velmi ochotně učí tréninková data a aproximuje pravděpodobnostní rozložení problému popsaného tréninkovou množinou pro malé hodnoty okolí neuronu ρ_0 a kroku okolí j . Síť s takovými parametry okolí je během učení náchylná na částečné (obr. 3.8) nebo úplné překroucení mřížky (obr. 3.9). Navíc „pozice“ neuronů uvnitř topologie sítě velmi závisí na počátečním nastavení vah. U variací parametrů, které dosahují vyšší hodnoty parametru odchylny, dojde k nežádoucím průběhům učení častěji. Takové variace jsou nevhodné pro výběr.

5.3.3 Srovnání parametru odchylny a parametru pokrytí

Vhodná variace parametrů učení byla vybrána porovnáním průběhů parametru odchylny a parametru pokrytí pro zvolené parametry učení, např. $\mu_0=0,8$; $k=0,05$. Pro tyto parametry jsou vykresleny na obr. 5.4 závislosti parametru odchylny i parametru pokrytí na parametrech ρ_0 a j .


Parametr odchylny i parametr pokrytí mohou pro některé variace parametrů učení nabývat minimálních hodnot zároveň. Tyto variace učicích parametrů představují vhodnou volbu pro danou tréninkovou množinu a daný model Kohonenovy neuronové sítě.



Obr. 5.4 Závislost Δ_s a Δ_d na kroku okolí j pro variace parametrů μ_0 , k , ρ_0 .

Při výběru parametrů učení musíme zvažovat další aspekty. I když vybíráme síť, jež je odolná na vliv počátečního nastavení vah (minimum parametru odchylny) a schopná se na předložená data naučit (dosahuje hodnot přibližně minima parametru pokrytí), zvažujeme také výpočtovou náročnost.

Vysoké hodnoty okolí ρ_0 způsobují, že při každém předložení tréninkového vzoru je přepočítáváno velké množství váhových vektorů. Stejně tak velký krok okolí j zvyšuje výpočetní dobu, protože se počítá s hodnotami vah okolních neuronů větší počet cyklů (viz graf 5.4). Také lze uvažovat, že pro velké hodnoty k má funkce parametru učení μ strmější pokles a tedy, je-li schopná se na předložená data naučit po 300 cyklech, dokáže se naučit i pro mnohem menší počet cyklů učení. Podobně tak volíme raději vyšší hodnoty μ_0 , která značí, jak rychle se mřížka sítě rozprostře v prostoru vstupních dat. V grafu 5.4 je vykreslena závislost parametru pokrytí na počtu provedených cyklů učení pro parametry $\mu_0=0,8$; $k=0,05$; $\rho=4$ a náhodné počáteční nastavení vah.



Graf 5.4 Závislost parametru pokrytí na počtu provedených cyklů.


5.4 Vybrané variace parametrů učení

Na základě uvedených předpokladů a zkušeností bylo vybráno několik variací parametrů. Tyto variace dále prochází výběrem nejvhodnější. Přehled vybraných variací poskytuje tab. 5.2.

Tab. 5.2 Přehled vhodných variací parametrů

variace	μ_0	k	ρ_0	j
1	0,3	0,05	4	10
2	0,6	0,05	3	8
3	0,6	0,05	4	8
4	0,8	0,05	3	14
5	0,8	0,05	4	8
6	0,8	0,07	6	4
7	0,9	0,05	3	12
8	1	0,07	3	12

Všechny z vybraných parametrů jsou vhodné pro naučení testovací množiny, pro kterou byla analýza prováděna. Síť však pro různé variace konverguje jinak rychle k minimu parametru pokrytí.




Graf 5.5 Rychlost konvergence jednotlivých variací parametrů.


Nejrychleji se naučí na předložená data varianty parametrů 2 a 6. Mají společnou jednu zásadní věc. Pro obě dvě platí, že násobek jejich okolí ρ_0 a kroku okolí j tedy $j \cdot \rho_0$ je roven 24. To znamená, že po 24 cyklech procesu učení nabývá okolí neuronu hodnoty 0. V takovém případě se po 24 cyklech začíná síť na předložená data doučovat.

Síť je pro všechny vybrané variace parametrů schopná konvergovat k minimu parametru pokrytí. Předpokládáme-li, že bude na vylepšení klasifikační schopnosti sítě využito metody LVQ, není vhodné nechat síť zcela naučit. Nedoučení lze ovlivnit volbou počtu kroků tak, aby síť ukončila proces učení před dosažením naučenosti.

Příklad byla vybrána variace č. 6 z tabulky 5.2. Síť s parametry učení $\mu_0=0,8$; $k=0,07$; $\rho_0=6$; $j=4$ pro 300 učicích cyklů dosahuje hodnoty parametru pokrytí přibližně 15,33 (viz mřížka sítě na obr. 5.5). Je-li snížen počet cyklů na hodnotu 26, parametr pokrytí nabývá hodnoty 18,66. To představuje přibližně 22% odchylku od minimální hodnoty. Výsledná mřížka sítě je uvedena na obr. 5.6.




Obr. 5.5 Mřížka vybrané sítě pro 300 cyklů učení.




Obr. 5.6 Mřížka vybrané sítě pro 26 cyklů učení.

5.4.1 Vhodnost vybraných parametrů učení


Parametry učení vybrané v tabulce 5.2 byly podrobeny testu na různá vstupní data. Množiny vstupních dat se liší jak počtem tréninkových vzorů, tak jejich rozložením. Výsledek je vyneseno do grafů na obrázcích 5.7, 5.8, 5.9, kde jsou také tréninková data na obrázcích vlevo. Jednalo se o síť 8x8 neuronů čtvercové topologie.



Obr. 5.7 Vyhodnocení variací pro dvě oddělené oblasti vstupních dat (152 vzorů).



Obr. 5.8 Vyhodnocení variací pro dvě proložené oblasti vstupních dat (104 vzorů).



Obr. 5.9 Vyhodnocení variací pro náhodné rozložení vstupních dat (1000 vzorů).


Z provedeného testu plyne, že již dříve vybraná variace parametrů učení č. 6 ($\mu_0=0,8$; $k=0,07$; $\rho_0=6$; $j=4$) vykazuje nejlepší výsledky. I přesto se projevila větší závislost na počátečním nastavení vah (viz. obr. 5.7 a 5.8). Obr. 5.9 dokazuje vhodnost aplikace Kohonenovy sítě na rovnoměrně rozložená data.

Jedinou variantou, jak zcela odstranit vliv počátečního nastavení vah, je nastavení parametru učení $\mu_0=1$. Pro $\mu_0=1$ je při adaptaci vah v prvním učícím cyklu „pozice“ vítězného neuronu položena na pozici předloženého vzoru (viz obr. 5.10). Také musí platit, že počáteční hodnota okolí ρ_0 je rovna největší topologické vzdálenosti mezi neurony v síti mínus jedna, např. pro síť 4x12 neuronů bude hodnota $\rho_0=11$. Tedy dáno vztahem:

$$\rho_0 = L - 1,$$

kde L je počet neuronů na delší straně mřížky. Síť se pro uvedené parametry během prvních učících cyklů shlukne v jeden bod, čímž je odstraněn vliv počátečního nastavení vah.

Pro síť 8x8 by mohly být parametry: $\mu_0=1$; $k=0,05$; $\rho_0=7$; $j=3$ nebo $\mu_0=1$; $k=0,07$; $\rho_0=7$; $j=3$. Potom i pro rozložení vstupních dat dle obrázku 5.7 nabývá parametr odchylky hodnotu 0,000. Jakákoliv jiná hodnota je numerickou chybou počítače.



Obr. 5.10 Shluknutí neuronů na jedinou pozici vzoru (oblast zvýrazněna červeným kruhem).

Výsledky diskutované touto kapitolou byly odvozeny pro síť o rozměrech 8x8 neuronů. Pro zobecnění by bylo třeba komplexnější citlivostní analýzy na parametry učení. Tato analýza by měla zvažovat dále volbu parametrů učení pro sítě různých rozměrů, větší počet rozmanitých testovacích množin s různým počtem testovacích vzorů. Vhodné by bylo také prozkoumání skutečného vlivu tvaru mřížky na doučovací schopnost sítě metodou LVQ a s tím souvisejícího počtu cyklů učení, potřebného k dosažení požadované míry naučení pro různé variace parametrů učení.

6 PROBLEMATIKA POČÁTEČNÍHO NASTAVENÍ VAH

6.1 Teoretické otázky počátečního nastavení vah

Výsledný stav Kohonenovy sítě po učení je reprodukovatelný, za předpokladu stejného počátečního nastavení vah, stejné tréninkové množiny a stejných parametrů učení. Protože však nelze rozhodnout, jaké je nejvhodnější počáteční nastavení vah, volí se hodnoty náhodně v prostoru vstupních dat, nejčastěji blízké nule.

V okamžik, kdy je do učení zanesena neurčitost ve formě náhodného nastavení vah, jsou také výsledné „pozice“ neuronů zatíženy odchylkou. Na problém proměnných výsledků v závislosti na počátečním nastavení vah narazili výzkumníci již dříve, proto byly navrženy následující modifikace klasického Kohonenova učení.

6.1.1 Modifikace Kohonenova učení

Jak se diskutuje v literatuře, např. [ŠN96], učení v Kohonenově síti mělo v původním návrhu za úkol sestrojít z neuronů své sítě množinu kandidátů, kteří mají stejnou pravděpodobnost výběru během aktivace sítě. Výborných výsledků dosahuje Kohonenovo učení pro rovnoměrné rozložení pravděpodobnostní funkce nad jednou ucelenou oblastí vstupních vzorů. Existují-li dvě a více odloučených skupin vstupních vzorů, nemusí být tato testovací množina sítí správně naučena. Následující tři modifikace Kohonenova učení tento jev potlačují a omezují vliv počátečního nastavení vah na výsledek [ŠN96].


Přidání šumu: K tréninkovým datům se přidají náhodné vektory rovnoměrně rozdělené v prostoru vstupních dat. Zpočátku je náhodných vektorů větší počet než tréninkových dat. Síť se učí na zašuměná data. S postupem času ubývá náhodných vektorů, které jsou odebírány, až se nakonec síť doučuje na původní vzory.

Radiální růst: Váhové vektory jsou nainicializovány blízké počátku vstupního prostoru. Tréninkové vzory jsou vynásobeny reálným číslem β , jež po inicializaci nabývá hodnoty blízké nule a postupem učení roste k jedné. Tak jsou donuceny váhy pomalejší adaptaci do okamžiku $\beta=0$, kdy již se učí na původní vzory.

Lokální paměť: Metoda staví na předpokladu, že mají-li mít kandidáti stejné pravděpodobnosti výběru, pak každý z k kandidátů bude mít právě $1/k$ pravděpodobnost na výběr zvolen. Jednotky si proto počítají četnost vyhraných kompetic a při překročení meze jsou dočasně vyřazeny z další kompetice.

6.2 Vliv počátečního nastavení vah

Počáteční nastavení vah má vliv na konečnou pozici „vítězných“ neuronů. Dokladem takového tvrzení může být obrázek 6.1. Tento obrázek ukazuje proměnnost mřížky pro jednu variaci parametrů učení, pevně danou množinu tréninkových dat a stejné parametry sítě, však pokaždé s náhodným nastavením vah sítě.



Obr. 6.1 Vliv počátečního nastavení vah na výsledné „pozice“ neuronu.


Na obrázku 6.1 jsou červeně zvýrazněny polohy vždy stejného neuronu v mříži (červené body). Modře je doplněna pomyslná „střední pozice“ vybraného neuronu. Červeným kruhem je zvýrazněna oblast výskytu tohoto neuronu vlivem počátečního nastavení vah. Levá část obr. 6.1 je vytvořena přeložením výsledných stavů mřížky sítě z devíti opakování učícího procesu. Další obrazové podklady k tomuto případu naleznete v příloze A. V uvedeném případě se jednalo o síť 8x8, 214 tréninkových vzorů (viz obrázek 5.3) ve 2D prostoru a s parametry učení: $\mu_0=0,8$; $k=0,01$; $\rho_0=4$; $j=10$.

Je třeba zodpovědět, zda se vliv počátečního nastavení vah projeví vždy, v jaké míře a jestli je možné jej omezit nebo mu zcela zabránit.

6.3 Vliv volby prostoru počátečního nastavení vah

V kapitole 5 byl vliv počátečního nastavení vah na výslednou konfiguraci sítě poměřován hodnotou parametru odchylky. Také byly předvedeny výsledky citlivostní analýzy sítě na parametry učení s náhodným nastavením vah na celém prostoru vstupních dat. V této kapitole bude zváženo, v literatuře často zmiňované, doporučení počátečního nastavení vah na hodnoty blízké nule. Bude předveden vliv počátečního nastavení vah na výslednou konfiguraci sítě pro správně zvolenou variaci parametrů učení a také pro dvě varianty nevhodné volby parametrů.

Protože programové prostřední nebylo navrženo původně pro prověření vlivu počátečního nastavení vah, nebylo možné prověřit modifikované varianty učení, jež jsou uvedeny v kapitole 6.1.1, další práce je zaměřena na prověření vlivu náhodného nastavení vah ve zvolených hranicích. Jsou prověřeny dvě varianty. Jednou z variant je náhodné nastavení vah sítě do prostoru vycházejícího ze středu prostoru vstupních dat. Druhou variantou je náhodné nastavení vah vycházející z jednoho z rohů prostoru vstupních dat (viz obr. 6.2).



Obr. 6.2 Počáteční nastavení vah: ve středním prostoru (vlevo), v rohovém prostoru (vpravo).


Vliv obou varianty byl prověřen pro vybrané parametry učení a různé hranice nastavení vah. Tyto hranice byly voleny v procentuálním poměru z rozměru vstupních dat. Např. dvojrozměrná data budou v mezích 0 až 450, potom lze nastavovat váhy pro 50 % rozměru dat v mezích od 0 do 250 (v rohovém prostoru) nebo od 125 do 375 (ve středním prostoru) pro oba rozměry.

Pro síť se čtvercovou topologií 8x8 neuronů a tréninkovou množinu 214 vzorů (viz obr. 5.3) byly vybrány tři ukázkové variace parametru:

Tab. 6.1 Příklady parametrů učení určené pro prověření vlivu inicializace vah


<i>případ</i>	μ_0	k	ρ_0	j
1	0,05	0,03	3	10
2	0,8	0,01	4	10
3	0,8	0,07	6	4

Pro každou variaci proběhlo 100 opakování učícího procesu o 300 cyklech pro vybrané hodnoty poměrného rozměru nastavení vah, a to jak ve středním, tak rohovém prostoru. Vyhodnocením výsledků takto proběhnoucí analýzy byl získán graf 6.1.



Graf 6.1 Závislost parametru odchylky na poměrném rozměru prostoru počátečního nastavení vah z rohu.


Graf 6.1 zachycuje parametr odchylky každé z 3 vybraných variant. 3. případ, který představuje síť zvolenou jako vhodnou, dosahuje nejnižších hodnot parametru odchylky s hodnotou 0,000. Parametr odchylky v případě 2. nabývá hodnot blízkých 40. Oba případy 2. a 3. jsou na poměrném rozměru prostoru počátečního nastavení vah nezávislé. Naopak případ 1. vyjadřuje silnou závislost na poměrném rozměru prostoru počátečního nastavení vah, kdy pro klesající procentuální hodnoty rozměru klesá hodnota parametru odchylky. Pro 1. případ je zachycen i rozdíl mezi iniciačním prostorem ze středu nebo z rohu datového prostoru (viz obr. 6.2).



Graf 6.2 Závislost parametru odchylky na poměrném rozměru prostoru počátečního nastavení vah.

Graf 6.2 zaznamenává skutečnost, že náhodné nastavení vah v rohovém prostoru snižuje parametr odchylky pro hodnoty poměrného rozměru prostoru nastavení vah menší než 70 %, kdežto počáteční nastavení vah ve středovém prostoru vstupních dat se projeví až pro hodnoty menší než 30 %. Tento výsledek potvrzuje doporučení uváděná v literatuře, že je vhodné volit počáteční nastavení vah náhodně na hodnoty blízké nule, tedy v rohovém prostoru vstupních dat. Nicméně vhodnou volbou parametrů učení, otázka počátečního nastavení vah ztrácí na významu. Mnohem důležitější je volba vhodných parametrů učení.

Během analýzy vlivu počátečního nastavení vah na parametr odchylky byla získána také data parametru pokrytí. Graf 6.3 zaznamenává vliv počátečního nastavení vah na parametr pokrytí s parametry $\mu_0=0,05$; $k=0,03$; $\rho_0=3$; $j=10$ (případ 1.) pro počáteční hodnoty vah, jak na středovém, tak na rohovém prostoru. Protože vliv na parametr pokrytí případů 2. a 3. je zanedbatelný, závislost pro tyto případy nebyla vynesena.



Graf 6.3 Závislost parametru pokrytí na poměrném rozměru prostoru počátečního nastavení vah.

Průběhy učení pro náhodné nastavení vah ve středovém prostoru a v rohovém prostoru jsou obrazově zaznamenán v příloze B a C.

Ve studii [Ekol11] je možné se dočíst o algoritmu, který počáteční nastavení vah a následné upravování vah koriguje pomocí genetického algoritmu. Celkový model uvedený ve studii má sloužit k optimalizaci návrhu topologie sítě a počátečního nastavení vah.

7 ZÁVĚR

V práci je ucelen teoretický základ znalostí umělých neuronových sítí, který dává možnost lépe vymezit prostor samoorganizujících neuronových sítí. Zadáním práce bylo mimo jiné seznámit se s problematikou samoorganizujících sítí se zaměřením na Kohonenovu síť. Teoretická část práce obsahuje mechanismy uplatňované u samoorganizujících sítí a především je popsáno učení Kohonenovy sítě v krocích následně podpořené obrazovým materiálem. Rešerše aplikací Kohonenovy sítě nabízí ukázky praktického využití vědomostí tykajících se Kohonenovy sítě.

Tato práce poskytuje popis programu Kohonenovy sítě vytvořeného Bc. Viktorem Žáčkem v rámci diplomové práce na Ústavu automatizace a měřicí techniky FEKT VUT v Brně. Tuto aplikaci jsem zvolil pro svoji bakalářskou práci.

V praktické části bakalářské práce jsem navrhl prostředek pro citlivostní analýzu výsledného stavu sítě na vybrané parametry. Hodnocení výsledného stavu sítě umožní parametr pokrytí a parametr odchylky. Ověřil jsem vliv počátečního nastavení vah na natočení nebo převrácení mřížky sítě, což způsobuje, že výsledná „pozice“ totožného neuronu není v mřížce stejná pro různá opakování učícího procesu.

S využitím programu Kohonenovy neuronové sítě jsem provedl rozsáhlou analýzu s omezením parametrů učení podle tabulky 5.1. Následným rozбором získaných dat byla omezena volba parametrů učení na užší oblast. Podle průběhů hodnot parametru pokrytí a parametru odchylky jsem našel vhodné parametry učení tak, aby byla síť schopna naučit se předložená vstupní data a zároveň aby vliv počátečního nastavení vah na výsledný stav sítě byl zanedbatelně malý, nebo žádný. Parametry učení vybrané na základě výsledků a vlastní zkušeností jsem prezentoval v tabulce 5.2.

Ze souboru vybraných variací parametrů učení jsem vyhodnotil prostřednictvím rychlosti konvergence sítě k minimu parametru pokrytí jako nejvhodnější variaci č. 6: $\mu_0=0,8$; $k=0,07$; $\rho_0=6$; $j=4$. Pro tyto parametry došlo nejrychleji k naučení sítě, a to během 28 cyklů učení na zvolené tréninkové množině 214 vzorů (obr. 5.3) pro síť se čtvercovou topologií o rozměrech 8x8 neuronů. Provedl jsem dále test na vliv počátečního nastavení vah pro různé tréninkové množiny (kapitola 5.4.1). Variace parametrů učení č. 6 se potvrdila jako nejvhodnější volba z vybraných variací.

Výsledky na tréninkové množině s oddělenými shluky tréninkových vzorů pro variaci č. 6 nedosahovaly uspokojivých hodnot, proto jsem navrhl parametry učení: $\mu_0=1$; $k=0,07$; $\rho_0=7$; $j=3$. Tyto parametry učení díky průběhu učení, který zaručují, zcela potlačují vliv počátečního nastavení vah a pro libovolnou tréninkovou množinu dosahují zanedbatelně malé (0,000) hodnoty parametru odchylky. Toto platí pro síť s 8x8 neurony. Aby byla zaručena rychlost a úplné naučení sítě, zvolil jsem malou hodnotu kroku okolí j .

Dále jsem se věnoval otázce vlivu počátečního nastavení vah na výsledný stav sítě. Na úvod jsou představeny modifikace Kohonenova učení, kterých se můžeme dočíst v běžně dostupné literatuře. Kapitola 6.2 graficky dokazuje pro pevné parametry učení, danou tréninkovou množinu a danou síť, že vliv počátečního nastavení vah existuje.

Pro analýzu vlivu počátečního nastavení vah na výslednou „pozici“ vítězných neuronů jsem zvolil odlišné varianty počátečního nastavení vah, než nabízí literatura. Váhy jsem náhodně nastavoval v mezích ve zvoleném poměru k rozměru vstupních dat a to buď ze středu, nebo z rohu. Pro různé poměry jsem do grafu 6.1 vynesl parametr odchylky. Takto získané průběhy byly provedeny pro 3 variace parametrů učení.

Z průběhů závislostí parametru pokrytí a parametru odchylky na poměrném rozměru prostoru počátečního nastavení vah (viz graf 6.1 a graf 6.2) lze vyvodit následující tvrzení:

1. tvrzení

Zmenšování prostoru počátečního nastavení vah pozitivně ovlivňuje parametr pokrytí a parametr odchylky, tedy snižuje hodnoty těchto parametrů.

2. tvrzení

Je vhodnější zvolit meze počátečního nastavení vah blízké nule (v rohovém prostoru na vstupních datech). Tímto se potvrzuje doporučení literatury.

3. tvrzení

Vhodnou volbou parametrů učení je vliv poměrného rozměru prostoru počátečního nastavení vah zanedbatelně malý.

4. tvrzení

Pro vhodně zvolené parametry učení je vliv počátečního nastavení vah na výsledné pozice vítězných neuronů zanedbatelně malý.

Parametry $\mu_0=0,8$; $k=0,07$; $\rho_0=6$; $j=4$ jsou vhodně zvoleny, proto v grafu 6.1 nedochází k výraznému ovlivnění parametru odchylky, tedy výsledného stavu sítě. Naopak parametry $\mu_0=0,05$; $k=0,03$; $\rho_0=3$; $j=10$ jsou velice závislé na prostoru počátečního nastavení vah.

Citlivostní analýzy v této práci byly prováděny na síti 8x8 neuronů. Pro zobecnění by byla potřeba komplexnější analýza. Další analýza by měla zvažovat dále volbu parametrů učení pro síť různých rozměrů (16x16, 32x32, atd.), pro větší počet rozmanitých testovacích množin s různým počtem testovacích vzorů. Vhodné by bylo také prozkoumání skutečného vlivu tvaru mřížky na doučovací schopnost sítě metodou LVQ a s tím související počet cyklů učení potřebný k dosažení požadované míry naučení pro různé variace parametrů učení.

Literatura

- [Ako108] AGGARWAL, Y. – KARAN, B. M. – DAS, B. N. – SINHA, R. K. An Unsupervised Neural Network to Predict the Level of Heat Stress. *Journal of Clinical Monitoring and Computing*, vol. 22, s. 425-430, 2008, 835215 Ranchi, India, DOI 10.1007/s10877-008-9152-x.
- [Eko111] ETTOUAIL, M. – GHANOU, Y. – ELMOUTAOUAKILE, K. – LAZAAR, M. A new architecture optimization model for the Kohonen networks and clustering, *Journal of Advanced Research in Computed Science*, vol. 3, s. 14-32, 2011, Fez, Morocco, ISSN: 1943-0221.
- [Fu75] FUKUSHIMA, K.: Cognitron: A self-organizing multi-layered neural network. *Biological Cybernetics*, 20:121-136, 1975.
- [Gr76] GROSSBERG, S.: Adaptive pattern classification and universal recording: I. parallel development and coding of neural feature detectors. *Biological Cybernetics*, 23:121-131, 1976.
- [Ma73] C. von der MALSBERG: Self-organizing of orientation sensitive cells in striate cortex. *Kybernetik*, 14:85-100, 1973.
- [MBB09] MEKSEN, T. M. – BOUDRAA, M. – BOUDRAA, B. Defects Clustering using Kohonen Networks during Ultrasonic Inspection. *IAENG International Journal of Computer Science*, Vol. 36, No. 3, s. 225-228, 2009, Algiers 16111, ALGERIA, ISSN:1819-656X.
- [MP69] MINSKY, M. L. – PAPERT, S. A.: *Perceptrons*, MIT Press, Cambridge MA, 1969.
- [MŠL93a] MAŘÍK, V. – ŠTĚPÁNKOVÁ, O. – LAŽANSKÝ, J.: *Umělá inteligence 1*. ACADEMIA 1993, Praha, ISBN 80-200-0496-3.
- [MŠL93b] MAŘÍK, V. – ŠTĚPÁNKOVÁ, O. – LAŽANSKÝ, J.: *Umělá inteligence 4*. ACADEMIA 1993, Praha, ISBN 80-200-0496-3.
- [Ni65] NILSSON, N. J.: *Learning machines*. McGraw-Hill, New-York, 1965.
- [Ro57] ROSENBLATT, Frank: *The Perceptron - a perceiving and recognizing automaton*. 1957, Report 85-460-1, Cornell Aeronautical Laboratory.
- [Sh04] SHOUHONG W.: Classification with incomplete survey data: a Hopfield neural network approach, In *Computers and operations research*, 2005, roč. 32, č. 10, s. 2583-2594.
- [ŠN96] ŠÍMA, J., NERUDA, R.: *Teoretické otázky neuronových sítí*. Praha: Matfyzpress, 1996. 390 s. ISBN 80-85863-18-9.
- [Tu08] TUČKOVÁ, J.: *Umělé neuronové sítě pomáhají lékařům FN Motol*. [online]. Datum publikace 2008-03-10 [cit. 2012-05-20]. Dostupné z URL: <<http://www.3pod.cz/254-Umele-neuronove-site-pomahaji-lekarum-FNMotol.html>>.

- [Vj06] VOJÁČEK, A.: *Samoučící se neuronová síť* [online]. Datum publikování 2006-05-14. Dostupné z URL: <<http://automatizace.hw.cz/mereni-a-regulace/ART244-samoucici-se{neuronova-sit{som-kohonenovy-mapy.html>>.
- [Vo02] VOLNÁ, E.: *Neuronové sítě I* [online]. Ostrava: Ostravská univerzita, 2002. 85 s. Elektronický text. Dostupné z URL: <<http://files.klaska.net/cvut/ns2/volna.pdf>>.
- [Žá12] ŽÁČEK, V.: *Kohonenova samo-organizační mapa*: semestrální práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav automatizace a měřicí techniky, 2012. 45 s. Vedoucí práce byl doc. Ing. Václav Jirsík, CSc.

Seznam symbolů

x	vstup
\mathbf{x}	vstupní vektor
w	váha
\mathbf{w}	váhový vektor
ζ	vnitřní potenciál neuronu
θ	prahová hodnota
w_0	bias
x_0	permanentní vstup
y	výstup sítě
p	počet tréninkových vzorů
m	počet neuronů ve výstupní vrstvě
n	počet vstupních neuronů (rozměr vstupních dat)
d	žádaná hodnota výstupu
c	index nejbližšího neuronu
T	tréninková množina
t	index tréninkového vzoru
\mathbf{t}	nová hodnota váhy pro tréninkový vzor
ε	mezní hodnota chyby, nebo krok parametru učení
d	vzdálenost neuronu a vstupního vektoru v kompetiční vrstvě
v	třída neuronu
α	parametr doučení (metoda LVQ)
μ_0	parametr učení
k	koefficient exponenciály
ρ_0	okolí neuronu
j	krok okolí
Δ_s	parametr odchylky
Δ_d	parametr pokrytí

Seznam zkratk

ART	Adaptivní Rezonanční Teorie
CNS	Centrální Nervová Soustava
ČVUT	České Vysoké Učení Technické
GUI	Grafical User Interface (grafické uživatelské rozhraní)
LVQ	Learning Vector Quantization (učící vektorová kvantizace)
RBF	Radiální Bazická Funkce
SOM	Samoorganizující Mapa
UNS	Umělá Neuronová Síť
VUT	Vysoké Učení Technické v Brně

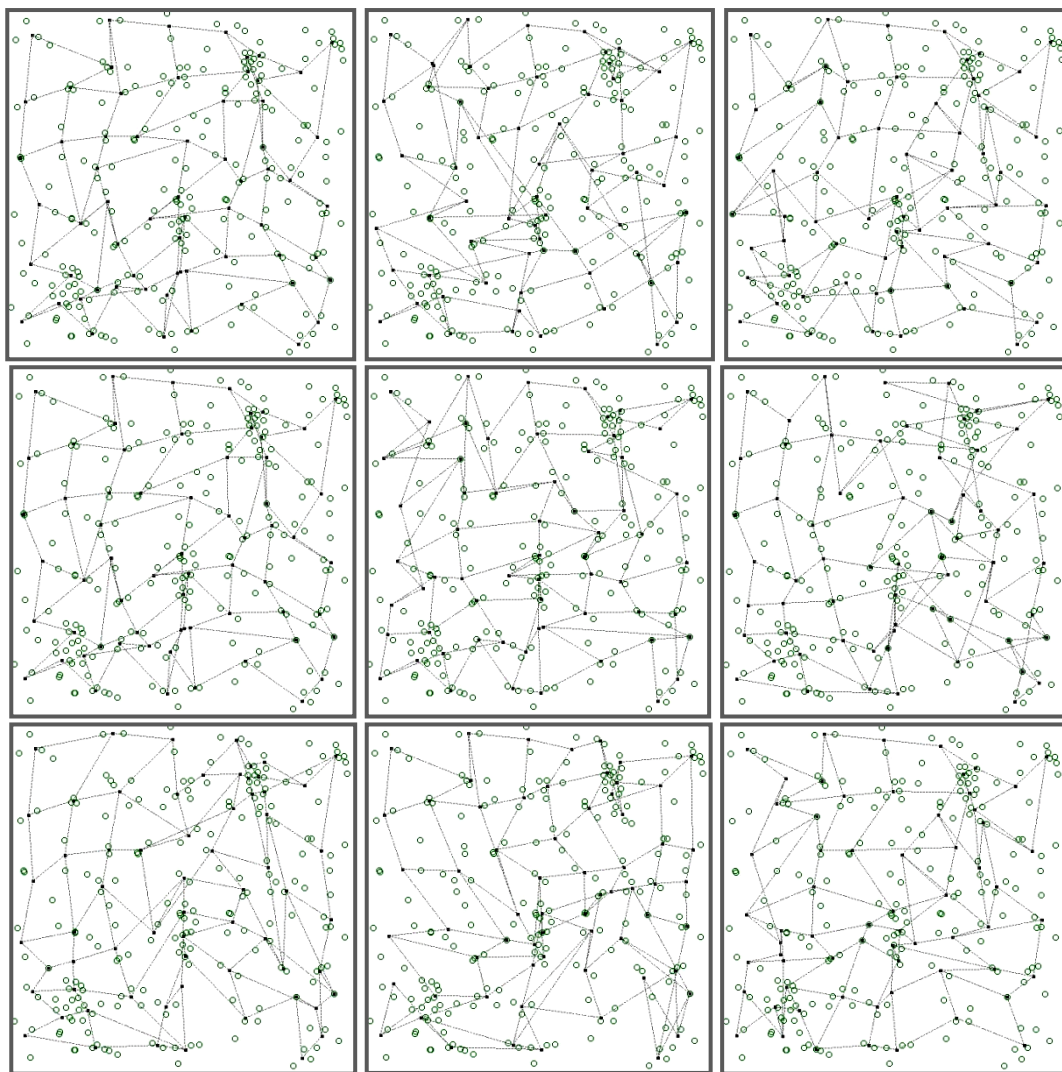
Seznam příloh

Příloha A	Obrazový doklad závislosti výsledných „pozic“ vítězných neuronů na počátečním nastavení vah.
Příloha B	Obrazový záznam učení sítě pro inicializaci ve středovém prostoru.
Příloha C	Obrazový záznam učení sítě pro inicializaci v rohovém prostoru.
Příloha D	Tabulka části naměřených hodnot při citlivostní analýze.
Příloha E	CD, obsahuje: <ul style="list-style-type: none">– elektronickou verzi bakalářské práce.– program „Kohonenova neuronová síť“– soubory tréninkových dat (.dat)– soubory nastavených sítí (.knn)– seznámení s programem „Kohonenova neuronová síť“– výsledek citlivostní analýzy (4 x Excel 2003) (053, 355, 558, 81)

8 PŘÍLOHY

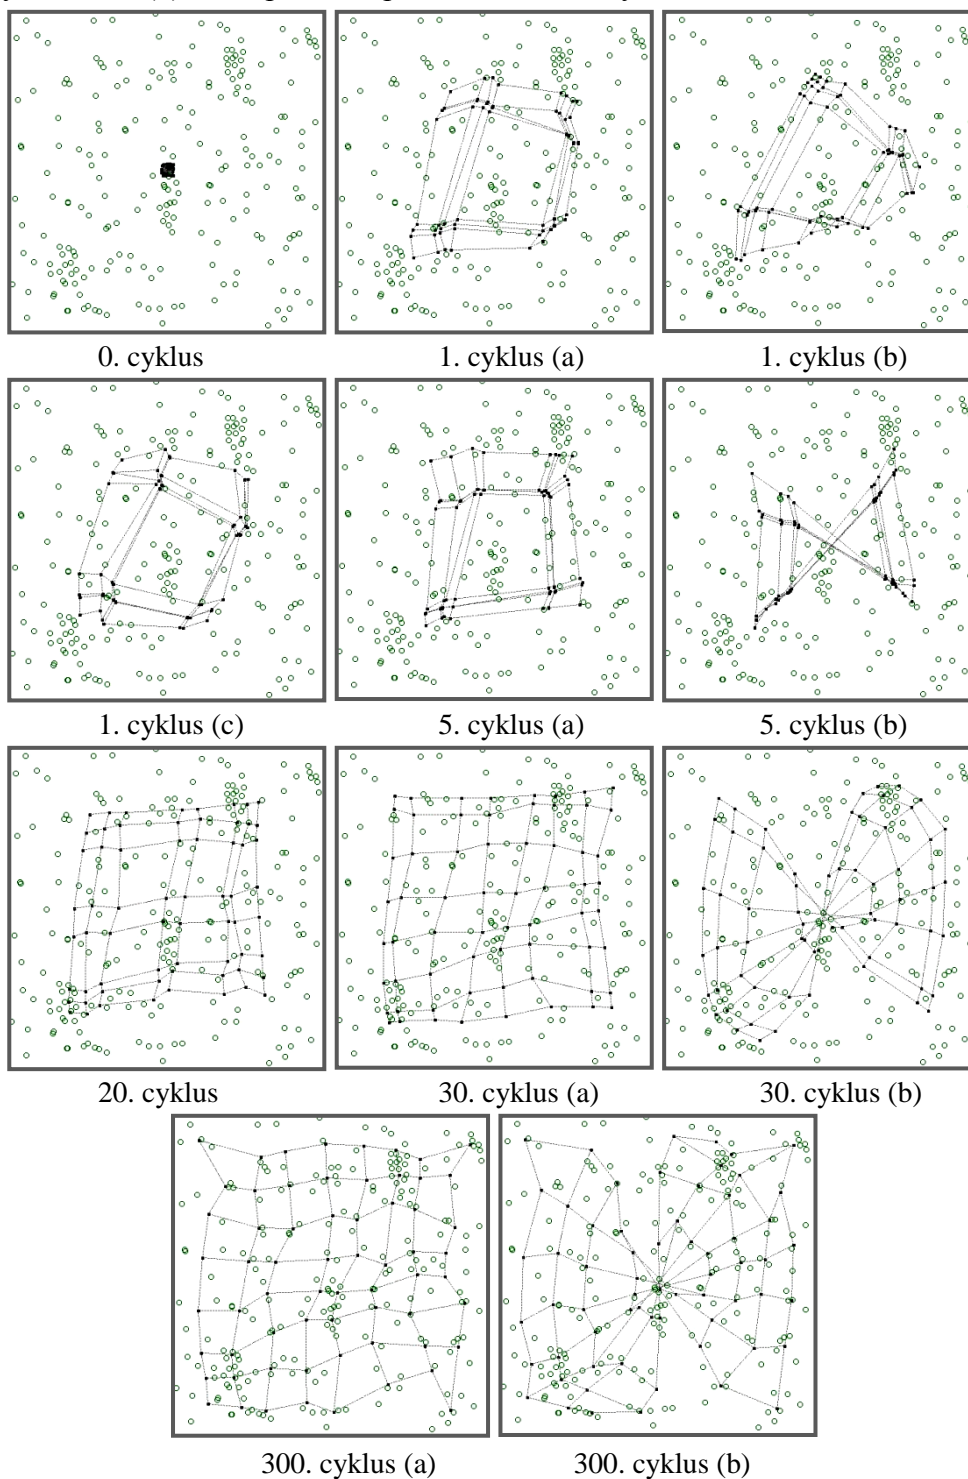
Příloha A

Obrazový doklad závislosti výsledných „pozic“ vítězných neuronů na počátečním nastavení vah. Následující snímky byly pořízeny pro stejné parametry sítě s čtvercovou topologií 8x8 neuronů a tréninkovou množinu 214 vzorů rozložených dle obr. 5.3. Parametry učení byly $\mu_0=0,8$; $k=0,01$; $\rho_0=4$ a $j=10$.



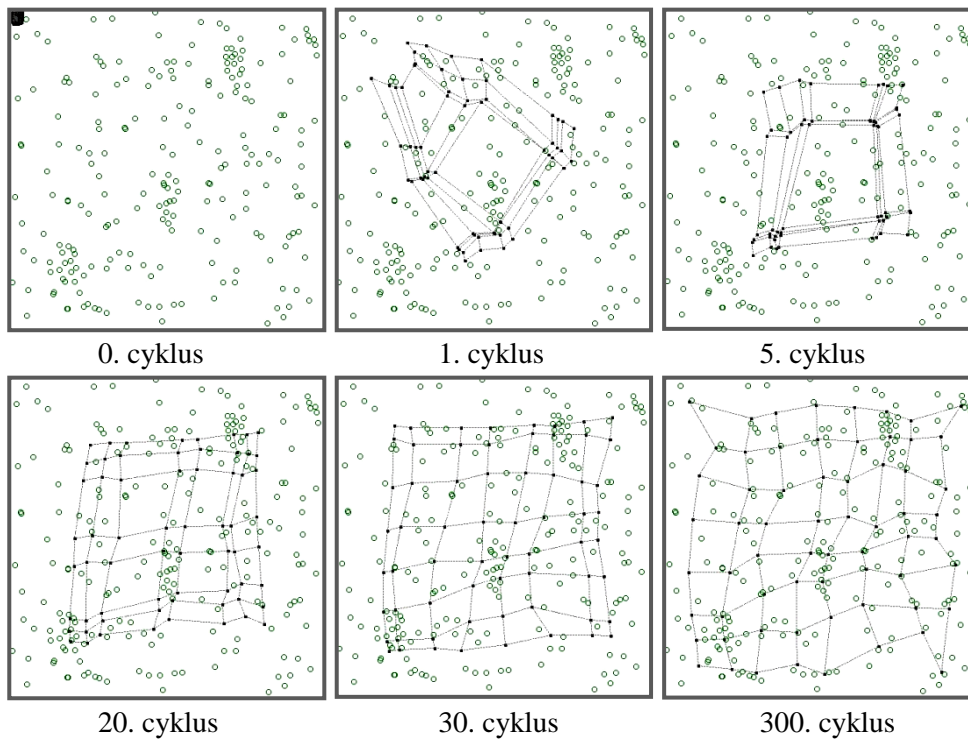
Příloha B

Obrazový záznam učení sítě pro inicializaci ve středovém prostoru. Následující snímky byly pořízeny pro stejné parametry sítě s čtvercovou topologií 8x8 neuronů a tréninkovou množinu 214 vzorů rozložených dle obr. 8.1. Parametry učení byly $\mu_0=0,05$; $k=0,03$; $\rho_0=3$ a $j=10$. Průběh je zachycen pro poměrný rozměr iniciačního prostoru 4 % pro různé kroky. Pro variantu (a) je průběh v pořádku bez překřížení mřížky, varianta (b) značí průběh s překřížením mřížky.



Příloha C

Obrazový záznam učení sítě pro inicializaci v rohovém prostoru. Následující snímky byly pořízeny pro stejné parametry sítě s čtvercovou topologií 8x8 neuronů a tréninkovou množinu 214 vzorů rozložených dle obr. 8.1. Parametry učení byly $\mu_0=0,05$; $k=0,03$; $\rho_0=3$ a $j=10$. Průběh je zachycen pro poměrný rozměr iniciačního prostoru 4 % pro různé kroky.



Příloha D

Tabulka naměřených hodnot z citlivostní analýzy (kapitola 5.2) v rozsahu $\mu_0=0,01\dots0,11$. Pro rozsáhlost datové databáze je uvedena jen malá část získaných dat.

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,01	2	3	0,04023	0	14,83109	102,0271
0,8	0,01	2	4	0,04023	0	14,81482	106,6647
0,8	0,01	2	5	0,04023	0	14,87096	92,765
0,8	0,01	2	6	0,04023	0	14,88537	95,69775
0,8	0,01	2	7	0,04023	0	14,96447	98,032
0,8	0,01	2	8	0,04023	0	14,89294	72,05317
0,8	0,01	2	9	0,04023	0	14,85777	69,04447
0,8	0,01	2	10	0,04023	0	14,78694	81,77547
0,8	0,01	2	11	0,04023	0	14,89125	61,84568
0,8	0,01	2	12	0,04023	0	14,85398	72,27396
0,8	0,01	2	13	0,04023	0	14,81619	69,22421
0,8	0,01	2	14	0,04023	0	14,77222	59,15372
0,8	0,01	2	15	0,04023	0	14,75462	54,3097
0,8	0,01	2	16	0,04023	0	14,53535	42,71724
0,8	0,01	2	17	0,04023	0	14,9006	50,02929
0,8	0,01	2	18	0,04023	0	14,59019	41,41791
0,8	0,01	3	3	0,04023	0	14,97214	120,0921
0,8	0,01	3	4	0,04023	0	14,84689	86,73991
0,8	0,01	3	5	0,04023	0	15,06136	75,77513
0,8	0,01	3	6	0,04023	0	15,04429	62,08031
0,8	0,01	3	7	0,04023	0	14,87526	64,69212
0,8	0,01	3	8	0,04023	0	14,73003	60,6615
0,8	0,01	3	9	0,04023	0	14,73827	70,54705
0,8	0,01	3	10	0,04023	0	14,81392	47,38028
0,8	0,01	3	11	0,04023	0	14,74778	52,12842
0,8	0,01	3	12	0,04023	0	14,73427	49,38106
0,8	0,01	3	13	0,04023	0	15,12486	31,8531
0,8	0,01	3	14	0,04023	0	14,87554	36,85867
0,8	0,01	3	15	0,04023	0	14,5968	32,6797
0,8	0,01	3	16	0,04023	0	14,47868	30,87
0,8	0,01	3	17	0,04023	0	15,03041	21,76358
0,8	0,01	3	18	0,04023	0	15,20349	25,16549
0,8	0,01	4	3	0,04023	0	14,78962	75,44239
0,8	0,01	4	4	0,04023	0	14,84502	64,62596
0,8	0,01	4	5	0,04023	0	14,89168	73,92246
0,8	0,01	4	6	0,04023	0	14,84216	72,33338
0,8	0,01	4	7	0,04023	0	14,70091	74,6122
0,8	0,01	4	8	0,04023	0	14,93825	52,94823
0,8	0,01	4	9	0,04023	0	14,70276	36,48125
0,8	0,01	4	10	0,04023	0	15,25095	34,5958

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,01	4	11	0,04023	0	14,68424	29,47148
0,8	0,01	4	12	0,04023	0	14,42423	33,4016
0,8	0,01	4	13	0,04023	0	15,46598	20,21676
0,8	0,01	4	14	0,04023	0	14,48861	16,32928
0,8	0,01	4	15	0,04023	0	15,02662	22,03902
0,8	0,01	4	16	0,04023	0	14,91727	17,88934
0,8	0,01	4	17	0,04023	0	15,28774	5,005119
0,8	0,01	4	18	0,04023	0	15,0625	16,6039
0,8	0,01	5	3	0,04023	0	14,73875	66,83151
0,8	0,01	5	4	0,04023	0	15,04828	54,46889
0,8	0,01	5	5	0,04023	0	14,92097	45,58836
0,8	0,01	5	6	0,04023	0	14,65796	49,11575
0,8	0,01	5	7	0,04023	0	14,49311	50,75779
0,8	0,01	5	8	0,04023	0	15,00724	31,01619
0,8	0,01	5	9	0,04023	0	14,85595	29,61724
0,8	0,01	5	10	0,04023	0	14,98968	27,1751
0,8	0,01	5	11	0,04023	0	15,2042	19,14291
0,8	0,01	5	12	0,04023	0	14,77304	19,27029
0,8	0,01	5	13	0,04023	0	14,56247	19,12894
0,8	0,01	5	14	0,04023	0	14,78431	7,338102
0,8	0,01	5	15	0,04023	0	15,07957	6,374448
0,8	0,01	5	16	0,04023	0	14,71951	2,61662
0,8	0,01	5	17	0,04023	0	14,42938	8,17E-14
0,8	0,01	5	18	0,04023	0	14,78497	7,95E-14
0,8	0,01	6	3	0,04023	0	14,85419	67,6936
0,8	0,01	6	4	0,04023	0	14,84263	41,13128
0,8	0,01	6	5	0,04023	0	15,19291	46,52792
0,8	0,01	6	6	0,04023	0	15,00093	22,7193
0,8	0,01	6	7	0,04023	0	14,76656	33,39949
0,8	0,01	6	8	0,04023	0	14,63809	25,5654
0,8	0,01	6	9	0,04023	0	14,89605	16,75194
0,8	0,01	6	10	0,04023	0	14,62231	9,08E-14
0,8	0,01	6	11	0,04023	0	14,9316	9,25E-14
0,8	0,01	6	12	0,04023	0	14,48042	5,977404
0,8	0,01	6	13	0,04023	0	14,91295	8,46E-14
0,8	0,01	6	14	0,04023	0	14,49603	8,474191
0,8	0,01	6	15	0,04023	0	14,86725	8,91E-14
0,8	0,01	6	16	0,04023	0	15,17219	7,42E-14
0,8	0,01	6	17	0,04023	0	15,09055	5,900649
0,8	0,01	6	18	0,04023	0	14,55501	9,42E-14
0,8	0,03	2	3	0,000102	0	14,91722	78,13676
0,8	0,03	2	4	0,000102	0	14,942	75,1906
0,8	0,03	2	5	0,000102	0	15,107	55,57402

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,03	2	6	0,000102	0	14,853	52,47516
0,8	0,03	2	7	0,000102	0	14,8146	49,24314
0,8	0,03	2	8	0,000102	0	14,79337	33,31352
0,8	0,03	2	9	0,000102	0	14,82855	32,9655
0,8	0,03	2	10	0,000102	0	14,88676	43,76915
0,8	0,03	2	11	0,000102	0	14,81362	22,99448
0,8	0,03	2	12	0,000102	0	14,5744	14,55272
0,8	0,03	2	13	0,000102	0	14,87275	21,83095
0,8	0,03	2	14	0,000102	0	14,81087	13,20862
0,8	0,03	2	15	0,000102	0	15,16728	14,69377
0,8	0,03	2	16	0,000102	0	14,82419	7,867947
0,8	0,03	2	17	0,000102	0	14,35623	11,1833
0,8	0,03	2	18	0,000102	0	14,34911	8,006343
0,8	0,03	3	3	0,000102	0	14,83875	66,47161
0,8	0,03	3	4	0,000102	0	14,87946	48,34843
0,8	0,03	3	5	0,000102	0	14,86256	35,18461
0,8	0,03	3	6	0,000102	0	14,98254	32,46943
0,8	0,03	3	7	0,000102	0	15,16451	22,53228
0,8	0,03	3	8	0,000102	0	14,63797	16,31885
0,8	0,03	3	9	0,000102	0	15,00822	14,75524
0,8	0,03	3	10	0,000102	0	15,19946	3,89E-08
0,8	0,03	3	11	0,000102	0	14,49122	10,10106
0,8	0,03	3	12	0,000102	0	14,82195	2,164077
0,8	0,03	3	13	0,000102	0	15,03892	4,323691
0,8	0,03	3	14	0,000102	0	14,27728	4,947443
0,8	0,03	3	15	0,000102	0	14,91173	5,509242
0,8	0,03	3	16	0,000102	0	15,00487	8,98E-14
0,8	0,03	3	17	0,000102	0	15,44276	8,16E-14
0,8	0,03	3	18	0,000102	0	15,36312	8,46E-14
0,8	0,03	4	3	0,000102	0	14,84256	57,72341
0,8	0,03	4	4	0,000102	0	15,04822	35,2639
0,8	0,03	4	5	0,000102	0	15,07059	27,17502
0,8	0,03	4	6	0,000102	0	14,77174	26,76962
0,8	0,03	4	7	0,000102	0	14,8273	19,49308
0,8	0,03	4	8	0,000102	0	14,99509	12,08561
0,8	0,03	4	9	0,000102	0	14,86335	9,930271
0,8	0,03	4	10	0,000102	0	14,74733	20,81643
0,8	0,03	4	11	0,000102	0	15,03854	7,52E-14
0,8	0,03	4	12	0,000102	0	15,00487	9,16E-14
0,8	0,03	4	13	0,000102	0	15,31027	8,94E-14
0,8	0,03	4	14	0,000102	0	14,99231	8,08E-14
0,8	0,03	4	15	0,000102	0	14,65276	7,29E-14
0,8	0,03	4	16	0,000102	0	14,19392	7,66E-14

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,03	4	17	0,000102	0	14,18181	8,42E-14
0,8	0,03	4	18	0,000102	0	14,92926	7,50E-14
0,8	0,03	5	3	0,000102	0	14,50634	20,97469
0,8	0,03	5	4	0,000102	0	14,93694	28,54422
0,8	0,03	5	5	0,000102	0	14,9377	20,1753
0,8	0,03	5	6	0,000102	0	14,88701	16,69743
0,8	0,03	5	7	0,000102	0	15,2066	5,846057
0,8	0,03	5	8	0,000102	0	15,12955	8,56E-14
0,8	0,03	5	9	0,000102	0	15,09828	8,83E-14
0,8	0,03	5	10	0,000102	0	15,03294	8,44E-14
0,8	0,03	5	11	0,000102	0	15,01784	8,67E-14
0,8	0,03	5	12	0,000102	0	14,65276	8,25E-14
0,8	0,03	5	13	0,000102	0	14,1954	7,38E-14
0,8	0,03	5	14	0,000102	0	14,84341	8,33E-14
0,8	0,03	5	15	0,000102	0	14,90129	9,20E-14
0,8	0,03	5	16	0,000102	0	14,9573	8,18E-14
0,8	0,03	5	17	0,000102	0	15,04658	9,01E-14
0,8	0,03	5	18	0,000102	0	14,99708	8,66E-14
0,8	0,03	6	3	0,000102	0	14,50793	26,05222
0,8	0,03	6	4	0,000102	0	14,02235	8,37E-14
0,8	0,03	6	5	0,000102	0	15,01593	1,01E-13
0,8	0,03	6	6	0,000102	0	14,6088	7,881742
0,8	0,03	6	7	0,000102	0	14,10932	8,57E-14
0,8	0,03	6	8	0,000102	0	14,88237	8,24E-14
0,8	0,03	6	9	0,000102	0	14,91619	8,30E-14
0,8	0,03	6	10	0,000102	0	14,65276	8,18E-14
0,8	0,03	6	11	0,000102	0	14,16231	0,899662
0,8	0,03	6	12	0,000102	0	14,50134	7,81E-14
0,8	0,03	6	13	0,000102	0	14,96427	8,57E-14
0,8	0,03	6	14	0,000102	0	14,99499	8,02E-14
0,8	0,03	6	15	0,000102	0	14,78153	8,33E-14
0,8	0,03	6	16	0,000102	0	15,09577	8,30E-14
0,8	0,03	6	17	0,000102	0	15,33893	0,001247
0,8	0,03	6	18	0,000102	0	15,76652	8,71E-14
0,8	0,05	2	3	2,57E-07	0	15,20232	62,93398
0,8	0,05	2	4	2,57E-07	0	14,9489	51,48149
0,8	0,05	2	5	2,57E-07	0	14,84142	55,42748
0,8	0,05	2	6	2,57E-07	0	14,97645	38,76972
0,8	0,05	2	7	2,57E-07	0	14,81169	29,8117
0,8	0,05	2	8	2,57E-07	0	14,89123	25,48854
0,8	0,05	2	9	2,57E-07	0	14,81083	20,16515
0,8	0,05	2	10	2,57E-07	0	14,74913	16,78676
0,8	0,05	2	11	2,57E-07	0	14,80129	10,76023

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,05	2	12	2,57E-07	0	14,65411	13,44184
0,8	0,05	2	13	2,57E-07	0	14,87696	10,31982
0,8	0,05	2	14	2,57E-07	0	14,97223	8,417388
0,8	0,05	2	15	2,57E-07	0	14,9784	4,720882
0,8	0,05	2	16	2,57E-07	0	14,67998	6,652051
0,8	0,05	2	17	2,57E-07	0	15,18405	0,334715
0,8	0,05	2	18	2,57E-07	0	15,1682	1,456403
0,8	0,05	3	3	2,57E-07	0	15,0658	53,43188
0,8	0,05	3	4	2,57E-07	0	15,05766	29,22119
0,8	0,05	3	5	2,57E-07	0	14,71055	20,85937
0,8	0,05	3	6	2,57E-07	0	15,01786	19,06066
0,8	0,05	3	7	2,57E-07	0	14,87931	14,15821
0,8	0,05	3	8	2,57E-07	0	14,93053	8,925253
0,8	0,05	3	9	2,57E-07	0	15,05506	6,07496
0,8	0,05	3	10	2,57E-07	0	15,00889	8,712709
0,8	0,05	3	11	2,57E-07	0	15,22247	6,552124
0,8	0,05	3	12	2,57E-07	0	15,00197	17,05406
0,8	0,05	3	13	2,57E-07	0	15,26642	8,43E-14
0,8	0,05	3	14	2,57E-07	0	15,24374	7,30E-14
0,8	0,05	3	15	2,57E-07	0	15,17926	7,68E-14
0,8	0,05	3	16	2,57E-07	0	15,23707	8,48E-14
0,8	0,05	3	17	2,57E-07	0	15,72198	7,73E-14
0,8	0,05	3	18	2,57E-07	0	15,50932	8,86E-14
0,8	0,05	4	3	2,57E-07	0	14,8546	29,30329
0,8	0,05	4	4	2,57E-07	0	15,22646	35,08461
0,8	0,05	4	5	2,57E-07	0	14,86744	16,32359
0,8	0,05	4	6	2,57E-07	0	14,43414	15,08657
0,8	0,05	4	7	2,57E-07	0	14,91063	7,84E-14
0,8	0,05	4	8	2,57E-07	0	14,12931	1,02E-13
0,8	0,05	4	9	2,57E-07	0	15,62822	8,54E-14
0,8	0,05	4	10	2,57E-07	0	14,2486	8,11E-14
0,8	0,05	4	11	2,57E-07	0	15,20136	8,13E-14
0,8	0,05	4	12	2,57E-07	0	15,23706	8,39E-14
0,8	0,05	4	13	2,57E-07	0	15,74616	8,49E-14
0,8	0,05	4	14	2,57E-07	0	16,10384	8,06E-14
0,8	0,05	4	15	2,57E-07	0	16,27283	8,49E-14
0,8	0,05	4	16	2,57E-07	0	16,21893	7,68E-14
0,8	0,05	4	17	2,57E-07	0	16,62341	8,21E-14
0,8	0,05	4	18	2,57E-07	0	17,2519	8,56E-14
0,8	0,05	5	3	2,57E-07	0	14,99768	23,74509
0,8	0,05	5	4	2,57E-07	0	15,18332	69,33894
0,8	0,05	5	5	2,57E-07	0	15,1234	8,7284
0,8	0,05	5	6	2,57E-07	0	14,97615	8,27E-14

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,05	5	7	2,57E-07	0	15,046	1,273188
0,8	0,05	5	8	2,57E-07	0	14,2486	1,28E-11
0,8	0,05	5	9	2,57E-07	0	15,17882	8,24E-14
0,8	0,05	5	10	2,57E-07	0	15,54585	9,47E-14
0,8	0,05	5	11	2,57E-07	0	15,89385	8,24E-14
0,8	0,05	5	12	2,57E-07	0	15,78121	7,95E-14
0,8	0,05	5	13	2,57E-07	0	16,24092	1,62E-13
0,8	0,05	5	14	2,57E-07	0	17,18286	3,01E-13
0,8	0,05	5	15	2,57E-07	0	17,51463	1,15E-09
0,8	0,05	5	16	2,57E-07	0	18,1068	9,01E-11
0,8	0,05	5	17	2,57E-07	0	18,91805	6,37E-12
0,8	0,05	5	18	2,57E-07	0	19,97526	9,73E-11
0,8	0,05	6	3	2,57E-07	0	14,53617	12,92517
0,8	0,05	6	4	2,57E-07	0	14,79162	10,09722
0,8	0,05	6	5	2,57E-07	0	14,87501	7,18E-14
0,8	0,05	6	6	2,57E-07	0	15,00005	8,71E-14
0,8	0,05	6	7	2,57E-07	0	15,24331	7,45E-14
0,8	0,05	6	8	2,57E-07	0	15,29616	8,88E-14
0,8	0,05	6	9	2,57E-07	0	15,63534	8,09E-14
0,8	0,05	6	10	2,57E-07	0	15,79316	2,21E-09
0,8	0,05	6	11	2,57E-07	0	16,60539	1,02E-13
0,8	0,05	6	12	2,57E-07	0	17,12131	2,95E-10
0,8	0,05	6	13	2,57E-07	0	17,79533	2,99E-07
0,8	0,05	6	14	2,57E-07	0	18,92373	0,650226
0,8	0,05	6	15	2,57E-07	0	20,01026	6,92E-14
0,8	0,05	6	16	2,57E-07	0	21,04152	1,25E-10
0,8	0,05	6	17	2,57E-07	0	22,17851	0,291857
0,8	0,05	6	18	2,57E-07	0	23,39835	0,021491
0,8	0,07	2	3	6,51E-10	0	15,0142	57,02792
0,8	0,07	2	4	6,51E-10	0	14,88038	42,00472
0,8	0,07	2	5	6,51E-10	0	15,13542	34,64636
0,8	0,07	2	6	6,51E-10	0	15,15252	20,58893
0,8	0,07	2	7	6,51E-10	0	14,93666	16,18049
0,8	0,07	2	8	6,51E-10	0	15,26993	12,91512
0,8	0,07	2	9	6,51E-10	0	14,83965	10,87836
0,8	0,07	2	10	6,51E-10	0	15,29323	3,37631
0,8	0,07	2	11	6,51E-10	0	15,41282	8,801798
0,8	0,07	2	12	6,51E-10	0	15,36042	4,222211
0,8	0,07	2	13	6,51E-10	0	15,24346	4,80776
0,8	0,07	2	14	6,51E-10	0	15,16441	6,633255
0,8	0,07	2	15	6,51E-10	0	15,51535	6,7393
0,8	0,07	2	16	6,51E-10	0	15,48782	0,256945
0,8	0,07	2	17	6,51E-10	0	15,48462	4,498583

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,07	2	18	6,51E-10	0	15,86072	4,167724
0,8	0,07	3	3	6,51E-10	0	15,16926	46,64997
0,8	0,07	3	4	6,51E-10	0	15,2232	18,80893
0,8	0,07	3	5	6,51E-10	0	14,98155	8,766072
0,8	0,07	3	6	6,51E-10	0	14,84755	8,827837
0,8	0,07	3	7	6,51E-10	0	14,90662	9,231684
0,8	0,07	3	8	6,51E-10	0	15,33528	1,561228
0,8	0,07	3	9	6,51E-10	0	15,24056	4,179097
0,8	0,07	3	10	6,51E-10	0	14,79243	26,18989
0,8	0,07	3	11	6,51E-10	0	15,71213	38,60332
0,8	0,07	3	12	6,51E-10	0	15,89514	38,13584
0,8	0,07	3	13	6,51E-10	0	16,34826	37,30003
0,8	0,07	3	14	6,51E-10	0	16,52491	34,85843
0,8	0,07	3	15	6,51E-10	0	17,07383	24,07812
0,8	0,07	3	16	6,51E-10	0	17,43383	40,393
0,8	0,07	3	17	6,51E-10	0	18,02025	66,63288
0,8	0,07	3	18	6,51E-10	0	18,79905	24,29537
0,8	0,07	4	3	6,51E-10	0	15,26122	23,87245
0,8	0,07	4	4	6,51E-10	0	14,66703	5,580089
0,8	0,07	4	5	6,51E-10	0	15,11201	19,5406
0,8	0,07	4	6	6,51E-10	0	15,47695	39,68944
0,8	0,07	4	7	6,51E-10	0	15,27409	60,24404
0,8	0,07	4	8	6,51E-10	0	15,52853	14,42391
0,8	0,07	4	9	6,51E-10	0	15,932	1,05E-13
0,8	0,07	4	10	6,51E-10	0	16,33076	9,06E-14
0,8	0,07	4	11	6,51E-10	0	16,45185	1,88E-09
0,8	0,07	4	12	6,51E-10	0	17,41635	1,70E-05
0,8	0,07	4	13	6,51E-10	0	18,25514	1,36E-07
0,8	0,07	4	14	6,51E-10	0	18,88978	1,53E-10
0,8	0,07	4	15	6,51E-10	0	19,85098	8,23E-14
0,8	0,07	4	16	6,51E-10	0	20,93186	4,91E-13
0,8	0,07	4	17	6,51E-10	0	21,95748	7,41E-14
0,8	0,07	4	18	6,51E-10	0	23,07594	5,56E-11
0,8	0,07	5	3	6,51E-10	0	15,10818	8,801829
0,8	0,07	5	4	6,51E-10	0	14,83002	17,4229
0,8	0,07	5	5	6,51E-10	0	15,21956	1,73E-05
0,8	0,07	5	6	6,51E-10	0	14,77879	5,12E-10
0,8	0,07	5	7	6,51E-10	0	15,88713	8,28E-14
0,8	0,07	5	8	6,51E-10	0	15,56017	1,968692
0,8	0,07	5	9	6,51E-10	0	16,81219	1,29E-12
0,8	0,07	5	10	6,51E-10	0	17,80239	3,16E-10
0,8	0,07	5	11	6,51E-10	0	18,66455	0,39755
0,8	0,07	5	12	6,51E-10	0	19,82108	8,82E-09

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,07	5	13	6,51E-10	0	21,37584	2,102102
0,8	0,07	5	14	6,51E-10	0	22,58904	9,51E-05
0,8	0,07	5	15	6,51E-10	0	23,90439	8,58E-14
0,8	0,07	5	16	6,51E-10	0	25,10929	0,000835
0,8	0,07	5	17	6,51E-10	0	26,17894	0,006444
0,8	0,07	5	18	6,51E-10	0	27,09392	0,281887
0,8	0,07	6	3	6,51E-10	0	15,07049	3,390974
0,8	0,07	6	4	6,51E-10	0	15,3347	8,20E-14
0,8	0,07	6	5	6,51E-10	0	15,43718	1,51E-11
0,8	0,07	6	6	6,51E-10	0	15,9417	0,755237
0,8	0,07	6	7	6,51E-10	0	16,38887	1,86E-05
0,8	0,07	6	8	6,51E-10	0	17,66651	2,317739
0,8	0,07	6	9	6,51E-10	0	18,43284	7,92E-08
0,8	0,07	6	10	6,51E-10	0	20,08052	8,83E-14
0,8	0,07	6	11	6,51E-10	0	21,54987	1,43E-05
0,8	0,07	6	12	6,51E-10	0	23,38248	0,103481
0,8	0,07	6	13	6,51E-10	0	24,90391	0,476927
0,8	0,07	6	14	6,51E-10	0	26,31427	0,350596
0,8	0,07	6	15	6,51E-10	0	27,82959	1,13E-06
0,8	0,07	6	16	6,51E-10	0	29,17403	0,204377
0,8	0,07	6	17	6,51E-10	0	30,65997	1,63E-05
0,8	0,07	6	18	6,51E-10	0	32,15492	0,414377
0,8	0,09	2	3	1,65E-12	0	15,08616	61,23984
0,8	0,09	2	4	1,65E-12	0	15,54305	34,28118
0,8	0,09	2	5	1,65E-12	0	15,17376	23,34229
0,8	0,09	2	6	1,65E-12	0	14,84315	17,7096
0,8	0,09	2	7	1,65E-12	0	14,6469	9,756405
0,8	0,09	2	8	1,65E-12	0	15,13464	8,577665
0,8	0,09	2	9	1,65E-12	0	15,23414	5,520852
0,8	0,09	2	10	1,65E-12	0	15,66471	7,820154
0,8	0,09	2	11	1,65E-12	0	14,99473	0,573078
0,8	0,09	2	12	1,65E-12	0	16,30031	3,607427
0,8	0,09	2	13	1,65E-12	0	16,19271	1,031664
0,8	0,09	2	14	1,65E-12	0	16,30283	2,540247
0,8	0,09	2	15	1,65E-12	0	16,79931	4,051431
0,8	0,09	2	16	1,65E-12	0	16,38188	9,56E-09
0,8	0,09	2	17	1,65E-12	0	17,01956	2,42E-09
0,8	0,09	2	18	1,65E-12	0	17,62162	0,815784
0,8	0,09	3	3	1,65E-12	0	14,87499	36,35264
0,8	0,09	3	4	1,65E-12	0	14,87493	19,51429
0,8	0,09	3	5	1,65E-12	0	15,38569	9,929046
0,8	0,09	3	6	1,65E-12	0	15,193	2,991221
0,8	0,09	3	7	1,65E-12	0	15,81749	4,267897

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,09	3	8	1,65E-12	0	15,76597	0,126396
0,8	0,09	3	9	1,65E-12	0	15,96241	16,44983
0,8	0,09	3	10	1,65E-12	0	16,55662	9,66E-13
0,8	0,09	3	11	1,65E-12	0	17,11808	8,47E-14
0,8	0,09	3	12	1,65E-12	0	18,08893	7,98E-14
0,8	0,09	3	13	1,65E-12	0	18,66422	8,60E-14
0,8	0,09	3	14	1,65E-12	0	19,59265	7,76E-14
0,8	0,09	3	15	1,65E-12	0	20,50707	8,23E-14
0,8	0,09	3	16	1,65E-12	0	21,38377	1,60E-07
0,8	0,09	3	17	1,65E-12	0	22,19155	4,61E-08
0,8	0,09	3	18	1,65E-12	0	23,09218	4,80E-13
0,8	0,09	4	3	1,65E-12	0	15,38584	8,986882
0,8	0,09	4	4	1,65E-12	0	15,36298	9,30E-14
0,8	0,09	4	5	1,65E-12	0	15,4222	7,037203
0,8	0,09	4	6	1,65E-12	0	15,75139	0,766028
0,8	0,09	4	7	1,65E-12	0	16,20929	1,96E-13
0,8	0,09	4	8	1,65E-12	0	16,9786	8,30E-05
0,8	0,09	4	9	1,65E-12	0	17,76332	2,26E-09
0,8	0,09	4	10	1,65E-12	0	18,95979	7,96E-14
0,8	0,09	4	11	1,65E-12	0	19,88419	1,45E-07
0,8	0,09	4	12	1,65E-12	0	21,22603	0,011776
0,8	0,09	4	13	1,65E-12	0	22,61232	1,32E-07
0,8	0,09	4	14	1,65E-12	0	23,78991	0,872273
0,8	0,09	4	15	1,65E-12	0	24,90158	3,27E-07
0,8	0,09	4	16	1,65E-12	0	25,87191	0,30253
0,8	0,09	4	17	1,65E-12	0	26,79699	0,376101
0,8	0,09	4	18	1,65E-12	0	27,65612	0,106558
0,8	0,09	5	3	1,65E-12	0	15,26598	17,81182
0,8	0,09	5	4	1,65E-12	0	15,24651	0,403322
0,8	0,09	5	5	1,65E-12	0	15,9926	1,26E-10
0,8	0,09	5	6	1,65E-12	0	16,6044	7,44E-07
0,8	0,09	5	7	1,65E-12	0	17,49093	0,337435
0,8	0,09	5	8	1,65E-12	0	19,02187	9,24E-07
0,8	0,09	5	9	1,65E-12	0	20,31473	0,258482
0,8	0,09	5	10	1,65E-12	0	22,06843	1,112179
0,8	0,09	5	11	1,65E-12	0	23,80275	0,403895
0,8	0,09	5	12	1,65E-12	0	25,36137	0,38791
0,8	0,09	5	13	1,65E-12	0	26,68125	0,503593
0,8	0,09	5	14	1,65E-12	0	27,95018	0,581707
0,8	0,09	5	15	1,65E-12	0	29,29075	8,98E-14
0,8	0,09	5	16	1,65E-12	0	30,54477	8,80E-14
0,8	0,09	5	17	1,65E-12	0	31,87157	0,451006
0,8	0,09	5	18	1,65E-12	0	33,19399	0,054439

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,09	6	3	1,65E-12	0	14,96628	10,42595
0,8	0,09	6	4	1,65E-12	0	15,9622	0,086179
0,8	0,09	6	5	1,65E-12	0	16,35164	2,099452
0,8	0,09	6	6	1,65E-12	0	18,10554	1,63E-07
0,8	0,09	6	7	1,65E-12	0	19,28171	1,311838
0,8	0,09	6	8	1,65E-12	0	21,34765	1,29E-06
0,8	0,09	6	9	1,65E-12	0	23,7465	0,526969
0,8	0,09	6	10	1,65E-12	0	25,6194	0,070453
0,8	0,09	6	11	1,65E-12	0	27,51479	1,266039
0,8	0,09	6	12	1,65E-12	0	29,46774	0,466748
0,8	0,09	6	13	1,65E-12	0	31,35025	0,411218
0,8	0,09	6	14	1,65E-12	0	33,46112	8,92E-14
0,8	0,09	6	15	1,65E-12	0	35,84757	0,061286
0,8	0,09	6	16	1,65E-12	0	38,77519	0,173516
0,8	0,09	6	17	1,65E-12	0	42,0924	0,199779
0,8	0,09	6	18	1,65E-12	0	45,57508	0,312461
0,8	0,11	2	3	4,16E-15	0	15,11454	51,25341
0,8	0,11	2	4	4,16E-15	0	15,13952	31,88387
0,8	0,11	2	5	4,16E-15	0	14,99317	31,17897
0,8	0,11	2	6	4,16E-15	0	15,35452	12,9296
0,8	0,11	2	7	4,16E-15	0	15,38568	10,90572
0,8	0,11	2	8	4,16E-15	0	15,92187	5,305731
0,8	0,11	2	9	4,16E-15	0	16,08505	3,729974
0,8	0,11	2	10	4,16E-15	0	16,44328	17,89744
0,8	0,11	2	11	4,16E-15	0	16,19839	5,02946
0,8	0,11	2	12	4,16E-15	0	16,71873	1,513296
0,8	0,11	2	13	4,16E-15	0	17,03241	1,568317
0,8	0,11	2	14	4,16E-15	0	17,62919	2,83E-07
0,8	0,11	2	15	4,16E-15	0	18,75936	2,82E-06
0,8	0,11	2	16	4,16E-15	0	19,43216	8,79E-11
0,8	0,11	2	17	4,16E-15	0	20,22546	7,10E-12
0,8	0,11	2	18	4,16E-15	0	20,65846	9,25E-13
0,8	0,11	3	3	4,16E-15	0	14,98589	19,36341
0,8	0,11	3	4	4,16E-15	0	15,0711	6,019913
0,8	0,11	3	5	4,16E-15	0	15,09036	6,865108
0,8	0,11	3	6	4,16E-15	0	15,57106	2,960677
0,8	0,11	3	7	4,16E-15	0	16,22346	2,09E-05
0,8	0,11	3	8	4,16E-15	0	16,74927	9,56E-10
0,8	0,11	3	9	4,16E-15	0	17,33077	3,70E-12
0,8	0,11	3	10	4,16E-15	0	18,63793	1,29E-13
0,8	0,11	3	11	4,16E-15	0	19,57103	8,06E-14
0,8	0,11	3	12	4,16E-15	0	20,70679	7,08E-14
0,8	0,11	3	13	4,16E-15	0	21,65929	7,80E-14

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,11	3	14	4,16E-15	0	22,93282	7,78E-14
0,8	0,11	3	15	4,16E-15	0	23,89729	0,003787
0,8	0,11	3	16	4,16E-15	0	24,71387	1,07E-13
0,8	0,11	3	17	4,16E-15	0	25,43349	1,013634
0,8	0,11	3	18	4,16E-15	0	26,10563	0,82881
0,8	0,11	4	3	4,16E-15	0	15,21354	8,47901
0,8	0,11	4	4	4,16E-15	0	15,58668	2,929024
0,8	0,11	4	5	4,16E-15	0	16,19783	0,01602
0,8	0,11	4	6	4,16E-15	0	15,96762	6,77E-12
0,8	0,11	4	7	4,16E-15	0	18,03503	8,94E-14
0,8	0,11	4	8	4,16E-15	0	18,94366	6,41E-11
0,8	0,11	4	9	4,16E-15	0	20,67532	0,635394
0,8	0,11	4	10	4,16E-15	0	22,28124	0,308694
0,8	0,11	4	11	4,16E-15	0	23,76951	0,997796
0,8	0,11	4	12	4,16E-15	0	25,20431	0,559103
0,8	0,11	4	13	4,16E-15	0	26,4019	0,09493
0,8	0,11	4	14	4,16E-15	0	27,45781	0,285945
0,8	0,11	4	15	4,16E-15	0	28,47007	7,57E-14
0,8	0,11	4	16	4,16E-15	0	29,559	0,06452
0,8	0,11	4	17	4,16E-15	0	30,68568	2,14E-12
0,8	0,11	4	18	4,16E-15	0	31,65906	6,50E-14
0,8	0,11	5	3	4,16E-15	0	14,83042	0,000474
0,8	0,11	5	4	4,16E-15	0	16,11321	9,77E-09
0,8	0,11	5	5	4,16E-15	0	17,05029	0,160069
0,8	0,11	5	6	4,16E-15	0	18,43533	1,587765
0,8	0,11	5	7	4,16E-15	0	20,45748	1,355518
0,8	0,11	5	8	4,16E-15	0	22,30694	0,565994
0,8	0,11	5	9	4,16E-15	0	24,47349	8,26E-14
0,8	0,11	5	10	4,16E-15	0	26,27884	0,576352
0,8	0,11	5	11	4,16E-15	0	27,99679	0,732179
0,8	0,11	5	12	4,16E-15	0	29,64067	0,426104
0,8	0,11	5	13	4,16E-15	0	31,22773	0,008611
0,8	0,11	5	14	4,16E-15	0	32,86929	0,818029
0,8	0,11	5	15	4,16E-15	0	34,59145	0,259165
0,8	0,11	5	16	4,16E-15	0	36,586	0,241576
0,8	0,11	5	17	4,16E-15	0	39,18189	0,467064
0,8	0,11	5	18	4,16E-15	0	41,99982	0,917716
0,8	0,11	6	3	4,16E-15	0	15,66731	3,062049
0,8	0,11	6	4	4,16E-15	0	16,85572	3,21E-07
0,8	0,11	6	5	4,16E-15	0	18,49212	4,72E-06
0,8	0,11	6	6	4,16E-15	0	20,83701	1,389005
0,8	0,11	6	7	4,16E-15	0	23,47087	0,781342
0,8	0,11	6	8	4,16E-15	0	26,00525	0,614079

μ_0	k	ρ_0	j	kon. μ	kon. ρ	parametr pokrytí	parametr odchylky
0,8	0,11	6	9	4,16E-15	0	28,3942	1,178666
0,8	0,11	6	10	4,16E-15	0	30,80609	0,32256
0,8	0,11	6	11	4,16E-15	0	33,34432	0,296879
0,8	0,11	6	12	4,16E-15	0	36,36064	0,185563
0,8	0,11	6	13	4,16E-15	0	40,10937	0,014136
0,8	0,11	6	14	4,16E-15	0	44,31249	0,293183
0,8	0,11	6	15	4,16E-15	0	48,63699	0,490829
0,8	0,11	6	16	4,16E-15	0	52,3855	0,234989
0,8	0,11	6	17	4,16E-15	0	55,20121	0,056428
0,8	0,11	6	18	4,16E-15	0	57,38917	0,037408